



Sveučilište u Zagrebu

RUDARSKO-GEOLOŠKO-NAFTNI FAKULTET

Tihomir Frangen

**ODREĐIVANJE ZNAČAJKI KRŠKOGA
VODONOSNIKA NA PODRUČJU
JUGOZAPADNOGA ŽUMBERKA
KVANTITATIVNIM TRASIRANJEM U
RAZLIČITIM HIDROLOŠKIM UVJETIMA**

DOKTORSKI RAD

Zagreb, 2013.



University of Zagreb

FACULTY OF MINING, GEOLOGY
AND PETROLEUM ENGINEERING

Tihomir Frangen

**DETERMINING THE CHARACTERISTICS
OF KARST AQUIFER ON
SOUTHWESTERN ŽUMBERAK AREA
USING QUANTITATIVE TRACING IN
VARIOUS HYDROLOGICAL
CONDITIONS**

DOCTORAL THESIS

Zagreb, 2013.



Sveučilište u Zagrebu

RUDARSKO-GEOLOŠKO-NAFTNI FAKULTET

Tihomir Frangen

**ODREĐIVANJE ZNAČAJKI KRŠKOGA
VODONOSNIKA NA PODRUČJU
JUGOZAPADNOGA ŽUMBERKA
KVANTITATIVNIM TRASIRANJEM U
RAZLIČITIM HIDROLOŠKIM UVJETIMA**

DOKTORSKI RAD

Mentor:

Doc. dr. sc. Jelena Parlov

Zagreb, 2013.



University of Zagreb

FACULTY OF MINING, GEOLOGY
AND PETROLEUM ENGINEERING

Tihomir Frangen

**DETERMINING THE CHARACTERISTICS
OF KARST AQUIFER ON
SOUTHWESTERN ŽUMBERAK AREA
USING QUANTITATIVE TRACING IN
VARIOUS HYDROLOGICAL
CONDITIONS**

DOCTORAL THESIS

Supervisor:

Doc. dr. sc. Jelena Parlov

Zagreb, 2013.

Mentor:

Dr. sc. Jelena Parlov

Docentica pri Rudarsko-geološko-naftnom fakultetu.

Zahvala...

...mentorici dr.sc. Jeleni Parlov, voditeljici na Institutu dr.sc. Željki Brkić i članici komisije dr.sc. Andrei Bačani;

...kolegama na Hrvatskom geološkom institutu koji su mi pomagali na terenu, ali i prenijeli puno znanja i iskustva nužnog za izradu ovog rada;

...dr.sc. Toniju Nikoliću na gostoprimstvu i skupljanju uzoraka vode;

...djelatnicima Parka prirode „Žumberak – Samoborsko gorje“ na pomoći i ustupljenim podacima;

...Ivani i Uni na strpljenju.

SAŽETAK

Vodonosnici krških izvora Jaža i Obrv na jugozapadnom Žumberku do sada nisu bili detaljno istraživani. Cilj istraživanja je bio definirati utjecaj različitih hidroloških uvjeta na parametre tečenja i transporta (srednja efektivna brzina i disperzija) kroz krške kanale na primjeru vodonosnika Jaže i Obrva. Dobivene spoznaje će ujedno pridonijeti boljem poznavanju građe i funkcioniranja samih vodonosnika. Osnovna metoda su bila kvantitativna trasiranja koja su ponavljana u različitim hidrološkim uvjetima i njihovi rezultati analizirani analitičkim modelima (metoda momenata, CDE, SFDM, MDM, 2RNE). Dodatno je analizirana dinamika izvora i ponora, prirodni traseri i hidrokemija izvorske vode.

Izveden je niz simultanih trasiranja ponora na kontaktu „Vivodinskog fliša“ i vapnenačkih breča. Traser je detektiran isključivo na izvoru Jaža. Dodatno je izvršeno trasiranje jame u naslagama dolomita. U tom slučaju traser je zabilježen isključivo na izvoru Obrv s vrlo neuobičajenom krivuljom koncentracije trasera.

Ustanovljeno je da su slivovi izvora Jaže i Obrv odvojeni. Napajanje Jaže dolazi s područja „Vivodinskog fliša“ i dijelom iz gornjokrednih vapnenačkih breča u zaleđu izvora. Obrv se napaja iz gornjotrijaskih „glavnih“ dolomita i gornjokrednih vapnenačkih breča. Naslage vapnenačkih breča, prethodno definirane kao osrednje propusne, kategorizirane su kao vrlo dobro propusne naslage.

Vodonosnici Jaže i Obrva se sastoje najvećim dijelom od dobro propusnih pukotina i krških kanala. Volumen sitnih pukotina i matriksa je kod njih netipično mali.

Srednja brzina trasera raste povećanjem količine vode u sustavu. Disperzija je najniža u uvjetima srednjih voda, a najveća u uvjetima visokih voda. Nailazak vodnih valova može povećati, ali i smanjiti disperziju ovisno o vremenu preklapanja.

Ključne riječi: kvantitativno trasiranje, hidrološki uvjeti, disperzija, srednja efektivna brzina, Jaža, Obrv

ABSTRACT

Karst aquifers from springs Jaža and Obrv haven't been thoroughly investigated until now. Purpose of this investigation was defining influence of various hydrological conditions on flow and transport parameters (mean flow velocity and dispersion) in karst conduits. The resulting findings will also contribute to a better understanding of the structure and functioning of the aquifers themselves. Basic method was repeated quantitative tracing in various hydrological conditions. Results were analyzed by analytical models (method of moments, CDE, SFDM, MDM, 2RNE). Additionally, flow dynamic with natural tracers and hydro chemical analysis were conducted.

A series of tracing tests on ponors on contact between "Vivodina flisch" and limestone breccias were conducted. Tracer was detected only in Jaža spring. Another tracing test done in the dolomites resulted in tracer appearing only on Obrv spring with very unusual tracer breakthrough curve.

Recharge of Jaža and Obrv springs are separated. Jaža spring recharges from "Vivodina flisch" and Upper Cretaceous limestone breccias. Obrv spring recharges from Upper Triassic "main" dolomites and Upper Cretaceous limestone breccias. Limestone breccias were reclassified from moderately permeable to very well permeable.

Jaže and Obrv aquifers consist mostly of well-permeable fractures and conduits. Volume of tiny cracks and matrix is untypically small.

Mean tracer velocity increases with increasing water volume in the system. Dispersion is the lowest during mean water conditions, and the largest during high water conditions. Storm events may increase, but also reduce dispersion depending on the time of overlap.

Keywords: quantitative tracing, hydrological conditions, dispersion, mean tracer velocity, Jaža, Obrv

SADRŽAJ

1	Uvod	1
2	Pregled dosadašnjih istraživanja	4
3	Značajke šireg istraživanog područja	6
3.1	Geografske i geomorfološke značajke.....	6
3.2	Klimatološke značajke	8
3.3	Osnovne geološke značajke Žumberka i Samoborskog gorja	11
3.3.1	Litostratigrafski pregled naslaga	12
3.4	Strukturna građa i tektonika.....	19
3.5	Hidrogeološke značajke	22
4	Značajke užeg istraživanog područja	24
5	Dinamika podzemnog sustava	28
5.1	Opis metoda i mjesta uspostave opažanja	28
5.2	Metode analiza	33
5.2.1	Analiza hidrograma	33
5.2.1.1	Recesijska analiza hidrograma.....	34
5.2.1.2	Konstrukcija glavne recesijske krivulje (GRK)	40
5.2.2	Analiza recesije na izvorima Jaža i Obrv	40
5.2.3	Analiza hidrograma i kemograma izvora	45
5.2.4	Analiza vodnih valova pomoću hidrograma i kemograma na izvorima Jaža i Obrv	47
5.2.5	Analiza vremenskih serija	51
5.2.5.1	Autokorelacijska funkcija.....	51
5.2.5.2	Kroskorelacijska funkcija	52
5.2.5.3	Odnosi vremenskih serija na izvorima Jaža i Obrv	53
6	Hidrogeokemijska svojstva vode	59

6.1	Metode i tehnike mjerenja	59
6.2	Metode obrade rezultata mjerenja	59
6.3	Obrada rezultata mjerenja	60
7	Kvantitativna trasiranja	67
7.1	Metodologija kvantitativnog trasiranja.....	68
7.1.1	Izračun pronosa	70
7.1.2	Procjena hidrauličkih i geometrijskih parametara kanala	70
7.1.3	Modeli za procjenu hidrauličkih parametara.....	74
7.1.3.1	Metoda momenata s Chatwinovom metodom.....	75
7.1.3.2	Ravnotežni konvekcijsko – disperzijski model (CDE).....	77
7.1.3.3	Jednopukotinski model disperzije (SFDM)	78
7.1.3.4	Multi disperzijski model (MDM).....	80
7.1.3.5	Neravnotežni dvo – zonski model (2RNE)	80
7.1.4	Geometrija kanala.....	82
7.1.5	Traseri.....	85
7.1.5.1	Natrijev fluorescein (Uranin)	86
7.1.5.2	Natrijev naftionat	88
7.1.6	Metode mjerenja koncentracije trasera	89
7.2	Opis trasiranih objekata.....	91
7.3	Opažачka mreža	92
7.4	Rezultati trasiranja.....	93
7.4.1	Trasiranje ponora P-1 izvedeno 11. svibnja 2009. godine	93
7.4.1.1	Osnovni parametri.....	94
7.4.1.2	Modelirani parametri	95
7.4.2	Trasiranje ponora P-1 izvedeno 21. srpnja 2011. godine.....	101
7.4.2.1	Osnovni parametri.....	102

7.4.2.2	Modelirani parametri	104
7.4.3	Trasiranje ponora P-2 izvedeno 21. srpnja 2011. godine.....	109
7.4.3.1	Osnovni parametri.....	110
7.4.3.2	Modelirani parametri	111
7.4.4	Trasiranje ponora P-1 izvedeno 23. veljače 2012. godine	116
7.4.4.1	Osnovni parametri.....	117
7.4.4.2	Modelirani parametri	119
7.4.5	Trasiranje ponora P-2 izvedeno 23. veljače 2012. godine	123
7.4.5.1	Osnovni parametri.....	124
7.4.5.2	Modelirani parametri	126
7.4.6	Trasiranje Jamine pod Piskom izvedeno 26. lipnja 2012. godine.....	130
7.4.6.1	Osnovni parametri.....	131
7.4.6.2	Modelirani parametri	133
7.4.7	Trasiranje ponora P-1 izvedeno 28. lipnja 2012. godine	136
7.4.7.1	Osnovni parametri.....	137
7.4.7.2	Modelirani parametri	139
7.4.8	Trasiranje ponora P-2 izvedeno 16. listopada 2012. godine	144
7.4.8.1	Osnovni parametri.....	145
7.4.8.2	Modelirani parametri	146
7.4.9	Trasiranje ponora P-1 izvedeno 16. listopada 2012. godine	152
7.4.9.1	Osnovni parametri.....	153
7.4.9.2	Modelirani parametri	154
7.4.10	Usporedba protoka na ponorima P-1 i P-2 s izvorom Jaža.....	159
8	Rasprava	161
8.1.1	Analiza primijenjenih modela	161
8.1.2	Pronos i bilanca mase.....	170

8.1.3	Utjecaj hidroloških uvjeta na parametre tečenja i transporta.....	172
8.1.4	Trasiranje Jamine pod Piskom.....	179
8.1.5	Volumeni kanala	183
8.1.6	Hidrogeološka klasifikacija naslaga na terenu	185
9	Zaključak	187
10	Literatura	191

POPIS SLIKA

Slika 3.1. Karta srednje godišnje temperature zraka.....	9
Slika 3.2. Karta srednjih godišnjih oborina	10
Slika 3.3. Srednja godišnja količina oborina na kišomjernim stanicama DHMZ-a u okolini istraživanog terena.....	11
Slika 3.4. Tektonska skica predneogenske podloge u širem području jugozapadnog dijela Panonskog bazena	20
Slika 3.5. Tektonska karta jugozapadnog Žumberka: 1. Kvartar; 2. Neogen; 3. Gornja kreda - mastriht; 4. Donja i gornja kreda (otriv – cenoman); 5. Jura; 6. Prebačene gornjotrijaske naslage kod Duralija; 7. Gornji trijas; 8. Srednji trijas; 9. Donji trijas; 10. Čelo navlake; 11. Rasjed s horizontalnim lijevim pomakom; 12. Reversni rasjed; 13. Normalni rasjed; 14. Rasjed s označenim nagibom rasjedne plohe; 15. Pretpostavljeni rasjed; 16. Normalna i prebačena os b; 17. Normalna i transgresivna granica; 18. Normalni i prebačeni slojevi. Legenda za preglednu kartu: Ž – Žumberak; UD – unutrašnji dinaridi; JSN – julijsko-savinjska navlaka; SN – savska navlaka, ADCP – jadransko-dinaridska karbonatna platforma; ZZ – Zagreb-Zemlen rasjed; PL – Perijadranski lineament; TS - Tisia	21
Slika 4.1. Hidrogeološka karta istraživanog područja.	25
Slika 5.1. Način postavljanja logera na opažane izvore i ponore.....	29
Slika 5.2. Protočna krivulja za izvor Jaža.	31
Slika 5.3. Protočna krivulja za izvor Obrv.	31
Slika 5.4. a – ADCP uređaj za mjerenje protoka; b – mjerenje protoka ADCP uređajem na izvoru Jaža	32
Slika 5.5. Kišomjer RG3-M proizvođača Hobo	33
Slika 5.6. Krivulje recesije jednostavnog sustava pražnjenja (A) i složenog sustava pražnjenja (B); slučaj linearnog sustava(C) i odgovarajuće krivulje recesije (D)	36
Slika 5.7. Shematski prikaz recesije s tri mikrorežima pražnjenja vodonosnika i odgovarajućih volumena vode.	37
Slika 5.8. Pokušaj dobivanja glavne krivulje recesije izvora Jaže „matchig strip“ metodom	41
Slika 5.9. Izdvojeni periodi recesije na izvoru Jaža. Pored recesije je napisan koeficijent recesije	42
Slika 5.10. Izdvojeni periodi recesije na izvoru Obrv. Pored recesije je napisan koeficijent recesije ...	42
Slika 5.11. Glavna recesijska krivulja izvora Jaža dobivena „matching strip“ metodom na prethodno odabranim recesijskim dijelovima.....	43
Slika 5.12. Glavna recesijska krivulja izvora Obrv dobivena „matching strip“ metodom na prethodno odabranim recesijskim dijelovima.....	44

Slika 5.13. Dvije hidraulički različite faze toka: vodni val i recesijski tok. Svaka faza odgovara različitom funkcioniranju sustava. Nijansa plave boje odražava rast ili pad koncentracije na izvoru kao funkcija protoka.....	46
Slika 5.14. Isječak hidrograma izvora Jaža sa Specifičnom elektrolitičkom vodljivošću. posebno su označeni vodni valovi za čijeg trajanja je izmjeren volumen vode koji predstavlja volumen freatskih kanala u datim uvjetima.....	48
Slika 5.15. Volumeni freatskih kanala izvora Jaža i hidrogram s naznačenim vodnim valovima na temelju kojih su napravljeni proračuni.	50
Slika 5.16. Volumeni freatskih kanala izvora Obrv i hidrogram s naznačenim vodnim valovima na temelju kojih su napravljeni proračuni.	50
Slika 5.17. Autokorelacijska funkcija izvora Jaža	54
Slika 5.18. Autokorelacijska funkcija izvora Obrv.....	55
Slika 5.19. Kroskorelacijska funkcija izvora Jaža i Obrv	56
Slika 5.20. Kroskorelacijska funkcija izvora Jaža i Obrv s oborinama na lokacijama Dančulovići i G. Oštrc	57
Slika 5.21. Kroskorelacijska funkcija protoka na izvoru Jaža i razina vode na ponorima P-1 i P-2	58
Slika 6.1. Piperov dijagram izvorskih voda Jaže	60
Slika 6.2. Piperov dijagram izvorskih voda Obrva	61
Slika 6.3. Piperov dijagram ponirućih voda ponora P-1 i P-2.....	62
Slika 6.4. Odnos koncentracije magnezija i $n(\text{Mg}^{2+})/n(\text{Ca}^{2+})$	63
Slika 6.5. Molarni odnos magnezija i kalcija u ovisnosti o protoku na izvoru Jaža	63
Slika 6.6. Odnos koncentracije magnezija $n(\text{Mg}^{2+})/n(\text{K}^{+})$ na izvoru Jaža.....	64
Slika 6.7. Molarni odnos magnezija i kalcija u ovisnosti o protoku na izvoru Obrv	65
Slika 6.8. Model miješanja za vode izvora Obrv.....	66
Slika 7.1. Primjer krivulje koncentracije trasera i njenih tipičnih elemenata: t_1 = vrijeme prvog nailaska, t_p = vrijeme maksimalne koncentracije, C_p = pik (maksimum) koncentracije, $t(R/2)$ = vrijeme kada je polovica detektiranog trasera prošla kroz mjesto opažanja, t_m (ADM) = srednje vrijeme dobiveno modelom advekcije-disperzije.	69
Slika 7.2. Usporedba mjerene krivulje koncentracije trasera (puna linija) s rezultatima različitih kalibriranih modela	73
Slika 7.3. Usporedba advektivno – disperzivnog modela i modela neravnoteže s opažanim podacima na izvoru Dyers.....	77

Slika 7.4. Konceptualni modeli tečenja kroz pukotinski vodonosnik. Lijevo koncept paralelnih pukotina među kojima je porozni matriks. Desno kanaliziranje toka u krškom vodonosniku.	79
Slika 7.5. Krivulja trasera s više pikova i pripadajući konceptualni model tečenja.....	80
Slika 7.6. Sedam jednostavnih tipova mreža kanala koji opisuju kretanje trasera. Tip mreže znatno utječe na rezultate trasiranja. q - protok na ulazu, Q – protok na izlazu, m_i – masa trasera ubačenog na ulazu, T_T – masa utvrđenog trasera na izlazu.....	83
Slika 7.7. Zavisnost intenziteta fluorescencije uranina i pH	87
Slika 7.8. Raspadanje dva uzorka uranina koncentracije $10\mu\text{g/l}$. Gornja krivulja predstavlja uzorak u smeđoj (tamnijoj) staklenoj boci, a donja uzorak u prozirnoj boci. Boce su bile izložene danjem svjetlu s malo sunčanog vremena.	88
Slika 7.9. Terenski fluorometri GGUN-FL-30 postavljeni na terenu; a – izvor Jaža; b – izvor Obrv.....	90
Slika 7.10. Spektrofluorometar Perkin-Elmer LS55 Hrvatskog geološkog instituta	91
Slika 7.11. Nacrt Jamine pod Piskom. Crvenom isprekidanom linijom je na profilu približno označena razina lažnog dna u vrijeme ubacivanja trasera.	92
Slika 7.12. Krivulja koncentracije trasera (uranina) i protoka na izvoru Jaža.....	94
Slika 7.13. Izračun Chatwinovog parametra za trasiranje uraninom izvedeno u svibnju 2009. godine	97
Slika 7.14. Rezultati CDE modela za trasiranje uraninom izvedeno u svibnju 2009. godine.....	98
Slika 7.15. Rezultati SFDM modela za trasiranje uraninom izvedeno u svibnju 2009. godine.....	99
Slika 7.16. Rezultati MDM modela za trasiranje uraninom izvedeno u svibnju 2009. godine.....	100
Slika 7.17. Rezultati 2RNE modela za trasiranje uraninom izvedeno u svibnju 2009. godine.....	101
Slika 7.18. Protok vode na ponoru P-1 u razdoblju od 1. srpnja 2011. godine, pa do kraja istjecanja trasera i količina oborina na najbližem kišomjeru u Radinoj Vasi	102
Slika 7.19. Krivulja koncentracije trasera (uranina) i protoka na izvoru Jaža.....	103
Slika 7.20. Izračun Chatwinovog parametra za trasiranje uraninom izvedeno u srpnju 2011. godine	105
Slika 7.21. Rezultati CDE modela za trasiranje uraninom izvedeno u srpnju 2011. godine	106
Slika 7.22. Rezultati SFDM i MDM modela za trasiranje uraninom izvedeno u srpnju 2011. godine .	107
Slika 7.23. Rezultati 2RNE modela za trasiranje uraninom izvedeno u srpnju 2011. godine	108
Slika 7.24. Protok vode na ponoru P-2 u razdoblju od 1. srpnja 2011. godine, pa do kraja istjecanja trasera i količina oborina na najbližem kišomjeru u Radinoj Vasi. Podaci o protoku su nedostupni za razdoblje prije 27.7.2011. godine radi premještanja logera.	109
Slika 7.25. Krivulja koncentracije trasera (naftionata) i protoka na izvoru Jaža.....	110

Slika 7.26. Izračun Chatwinovog parametra za trasiranje naftionatom izvedeno u srpnju 2011. godine	113
Slika 7.27. Rezultati CDE modela za trasiranje naftionatom izvedeno u srpnju 2011. godine	114
Slika 7.28. Rezultati SFDM i MDM modela za trasiranje naftionatom izvedeno u srpnju 2011. godine	115
Slika 7.29. Rezultati 2RNE modela za trasiranje naftionatom izvedeno u srpnju 2011. godine	116
Slika 7.30. Protok vode na ponoru P-1 u razdoblju od 1. veljače 2012. godine, pa do kraja istjecanja trasera i količina oborina na najbližem kišomjeru u Radinoj Vasi	117
Slika 7.31. Krivulja koncentracije trasera (uranina) i protoka na izvoru Jaža	118
Slika 7.32. Izračun Chatwinovog parametra za trasiranje uraninom izvedeno u veljači 2012. godine	120
Slika 7.33. Rezultati CDE modela za trasiranje uraninom izvedeno u veljači 2012. godine	121
Slika 7.34. Rezultati SFDM i MDM modela za trasiranje uraninom izvedeno u veljači 2012. godine	122
Slika 7.35. Rezultati 2RNE modela za trasiranje uraninom izvedeno u veljači 2012. godine	123
Slika 7.36. Protok vode na ponoru P-2 u razdoblju od 1. veljače 2012. godine, pa do kraja istjecanja trasera i količina oborina na najbližem kišomjeru u Radinoj Vasi	124
Slika 7.37. Krivulja koncentracije trasera (naftionata) i protoka na izvoru Jaža	125
Slika 7.38. Izračun Chatwinovog parametra za trasiranje naftionatom izvedeno u veljači 2012. godine	127
Slika 7.39. Rezultati CDE modela za trasiranje naftionatom izvedeno u veljači 2012. godine	128
Slika 7.40. Rezultati SFDM i MDM modela za trasiranje naftionatom izvedeno u veljači 2012. godine	129
Slika 7.41. Rezultati 2RNE modela za trasiranje naftionatom izvedeno u veljači 2012. godine	130
Slika 7.42. Protok vode na izvoru Obrv u razdoblju od 1. lipnja 2012. godine, pa do kraja istjecanja trasera i količina oborina na najbližem kišomjeru u Gornjem Oštrcu	131
Slika 7.43. Krivulja koncentracije trasera (uranina) i protoka na izvoru Obrv	132
Slika 7.44. Izračun Chatwinovog parametra za trasiranje uraninom izvedeno u lipnju 2012. godine	134
Slika 7.45. Rezultati MDM modela za trasiranje uraninom izvedeno u lipnju 2012. godine	135
Slika 7.46. Protok vode na ponoru P-1 u razdoblju od 1. lipnja 2012. godine, pa do kraja istjecanja trasera i količina oborina na najbližem kišomjeru u Radinoj Vasi	137
Slika 7.47. Krivulja koncentracije trasera (naftionata) i protoka na izvoru Jaža	138
Slika 7.48. Izračun Chatwinovog parametra za trasiranje naftionatom izvedeno u lipnju 2012. godine	140

Slika 7.49. Rezultati CDE modela za trasiranje naftionatom izvedeno u lipnju 2012. godine.....	141
Slika 7.50. Rezultati SFDM i MDM modela za trasiranje naftionatom izvedeno u lipnju 2012. godine.....	142
Slika 7.51. Rezultati 2RNE modela za trasiranje naftionatom izvedeno u lipnju 2012. godine.....	143
Slika 7.52. Protok vode na ponoru P-2 u razdoblju od 1. listopada 2012. godine, pa do kraja istjecanja trasera i količina oborina na najbližem kišomjeru u Radinoj Vasi. Maksimalni protok nedostaje jer je u tim uvjetima protok nemoguće izmjeriti.	144
Slika 7.53. Krivulja koncentracije trasera (naftionata) i protoka na izvoru Jaža.....	145
Slika 7.54. Izračun Chatwinovog parametra za trasiranje naftionatom izvedeno u listopadu 2012. godine	148
Slika 7.55. Rezultati CDE modela za trasiranje naftionatom izvedeno u listopadu 2012. godine.....	149
Slika 7.56. Rezultati SFDM i MDM modela za trasiranje naftionatom izvedeno u listopadu 2012. godine	150
Slika 7.57. Rezultati 2RNE modela za trasiranje naftionatom izvedeno u listopadu 2012. godine.....	151
Slika 7.58. Protok vode na ponoru P-1 u razdoblju od 1. listopada 2012. godine, pa do kraja istjecanja trasera i količina oborina na najbližem kišomjeru u Radinoj Vasi. Maksimalni protok nedostaje jer je u tim uvjetima protok nemoguće izmjeriti.	152
Slika 7.59. Krivulja koncentracije trasera (uranina) i protoka na izvoru Jaža.....	153
Slika 7.60. Izračun Chatwinovog parametra za trasiranje uraninom izvedeno u listopadu 2012. godine	156
Slika 7.61. Rezultati CDE modela za trasiranje uraninom izvedeno u listopadu 2012. godine	157
Slika 7.62. Rezultati SFDM i MDM modela za trasiranje uraninom izvedeno u listopadu 2012. godine	158
Slika 7.63. Rezultati 2RNE modela za trasiranje uraninom izvedeno u listopadu 2012. godine	159
Slika 7.64. Zbirni hidrogrami protoka na ponorima P-1 i P-2 i protoka na izvoru Jaža u vrijeme izvođenja trasiranja.....	160
Slika 8.1. Usporedba longitudinalne disperzije u ovisnosti o primijenjenom modelu. Nisu prikazani rezultati trasiranja Jamine pod Piskom niti rezultati MDM modela. Trasiranja su razvrstana po mjestu i vremenu ubacivanja trasera. Obratiti pažnju na logaritamsko mjerilo ordinate (disperzije).....	163
Slika 8.2. Konceptualni model geometrije i tečenja kroz krški kanal.....	164
Slika 8.3. Geometrija kanala sa strujnicama tečenja vode u bazenima i brzacima: (A) kanal konstantne širine; (B) kanal nepravilne širine; (C) trapezoidni bazen; (D) bazen s jednom preprekom; (E) „laboratorijski“ bazen; (F) bazen s dijagonalno nasuprotnim ulazom/izlazom; (G) bazen s tri prepreke; (H) hidraulički skok ili brzac.	165

Slika 8.4. Disperzija i retardacija uzrokovana različitom geometrijom kanala sa Slika 8.3. Veći vrtlozi uzrokuju veću retardaciju.....	166
Slika 8.5. Usporedba srednjeg vremena prolaska trasera u ovisnosti o primijenjenom modelu. Nisu prikazani rezultati trasiranja Jamine pod Piskom niti rezultati MDM modela. Trasiranja su razvrstana po mjestu i vremenu ubacivanja trasera.....	167
Slika 8.6. Utjecaj dinamike toka tijekom trasiranja na rezultate modela	169
Slika 8.7. Iznosi pronosa za sva trasiranja napravljena u sklopu ovog istraživanja. Trasiranja su razvrstana po mjestu i vremenu ubacivanja trasera.....	170
Slika 8.8. Normalizirane krivulje koncentracije trasera za sva izvedena trasiranja. Razvrstana su po mjestu ubacivanja trasera i vremenu izvođenja.	172
Slika 8.9. Protoci na izvorima na kojima je zabilježena pojava trasera u vremenu trajanja istjecanja trasera. Brojem je istaknuti prosječni protok.	173
Slika 8.10. Brzine prvog nailaska trasera za sva trasiranja. Brzine su izračunate koristeći pravocrtnu udaljenost mjesta ubacivanja i detekcije trasera sukladno dosadašnjoj praksi u našim krajevima. ...	174
Slika 8.11. Srednja efektivna brzina trasera za sva trasiranja. Brzine su izračunate koristeći modificiranu udaljenost mjesta ubacivanja i detekcije trasera te nisu izravno usporediva s prikazanim brzinama prvog nailaska. Brzine su napisane samo za metodu momenata.	175
Slika 8.12. Disperzivnost za sva trasiranja.....	176
Slika 8.13. Pecletov broj za sva trasiranja. Obratiti pažnju na logaritamsko mjerilo ordinate (Pecletovog broja).....	177
Slika 8.14. Procjena volumena kanala koji sudjeluju u toku za pojedinačna trasiranja. Procjena je napravljena na temelju srednjeg efektivnog vremena dobivenog metodom momenata. Iznimka je trasiranje Jamine pod Piskom gdje je označen i volumen dobiven na temelju prvog pika MDM modela (manji volumen).	178
Slika 8.15. Krivulja koncentracije trasera (uranina), protoka na izvoru Obrv i količina dnevnih oborina zabilježenih na kišomjeru u selu Gornji Oštrc.	179
Slika 8.16. Karta gradijenta reljefa (gradijent izračunat pomoću visine terena i horizontalne udaljenosti) za Jaminu pod Piskom.	181
Slika 8.17. Moguće objašnjenje rezultata trasiranja Jamine pod Piskom. Različitim bojama su označeni potencijali u glavnom kanalu i spremniku s vodom i traserom, te smjer tečenja vode: crvena boja - vrijeme upuštanja 70 m ³ vode s traserom; narančasta boja - nakon završetka upuštanja trasera; zelena boja – pad potencijala u glavnom kanalu uslijed dovoljno duge recesije.	183

POPIS TABLICA

Tablica 5.1. Pregled metoda analize recesijskih dijelova hidrograma.....	39
Tablica 5.2. Rezultati analiza odaziva izvora Jaže i Obrva na nailazak vodnih valova.....	49
Tablica 7.1. Osnovni parametri trasiranja ponora P-1 izvedenog u svibnju 2009. godine. Prividne brzine su izračunate pomoću korigirane udaljenosti.	95
Tablica 7.2. Rezultati modela za parametre toka i transporta trasiranja izvedenog u svibnju 2009. godine	96
Tablica 7.3. Osnovni parametri trasiranja ponora P-1 izvedenog u srpnju 2011. godine. Prividne brzine su izračunate pomoću korigirane udaljenosti.	103
Tablica 7.4. Rezultati modela za parametre toka i transporta trasiranja izvedenog u srpnju 2011. godine	104
Tablica 7.5. Osnovni parametri trasiranja ponora P-2 izvedenog u srpnju 2011. godine. Prividne brzine su izračunate pomoću korigirane udaljenosti.	111
Tablica 7.6. Rezultati modela za parametre toka i transporta trasiranja izvedenog u srpnju 2011. godine	112
Tablica 7.7. Osnovni parametri trasiranja ponora P-1 izvedenog u veljači 2012. godine. Prividne brzine su izračunate pomoću korigirane udaljenosti.	118
Tablica 7.8. Rezultati modela za parametre toka i transporta trasiranja izvedenog u veljači 2012. godine	119
Tablica 7.9. Osnovni parametri trasiranja ponora P-2 izvedenog u veljači 2012. godine. Prividne brzine su izračunate pomoću korigirane udaljenosti	125
Tablica 7.10. Rezultati modela za parametre toka i transporta trasiranja izvedenog u veljači 2012. godine	126
Tablica 7.11. Osnovni parametri trasiranja Jamine pod Piskom izvedenog u lipnju 2012. godine. Prividne brzine su izračunate pomoću korigirane udaljenosti	132
Tablica 7.12. Rezultati modela za parametre toka i transporta trasiranja izvedenog u lipnju 2012. godine	133
Tablica 7.13. Osnovni parametri trasiranja ponora P-1 izvedenog u lipnju 2012. godine. Prividne brzine su izračunate pomoću korigirane udaljenosti	138
Tablica 7.14. Rezultati modela za parametre toka i transporta trasiranja izvedenog u lipnju 2012. godine	139
Tablica 7.15. Osnovni parametri trasiranja ponora P-2 izvedenog u listopadu 2012. godine. Prividne brzine su izračunate pomoću korigirane udaljenosti	146

Tablica 7.16. Rezultati modela za parametre toka i transporta trasiranja izvedenog u listopadu 2012. godine	147
Tablica 7.17. Osnovni parametri trasiranja ponora P-1 izvedenog u listopadu 2012. godine. Prividne brzine su izračunate pomoću korigirane udaljenosti	154
Tablica 7.18. Rezultati modela za parametre toka i transporta trasiranja izvedenog u listopadu 2012. godine	155

POPIS OZNAKA

t – vrijeme (T)

α – koeficijent recesije (dan^{-1})(T^{-1})

t_0 – početno vrijeme

Q_0 – protok na početku recesije u vrijeme t_0 (m^3/s)

Q_t – protok u nekom vremenu t (m^3/s)

V_t – volumen uskladištene vode iznad razine izvora

N – broj eksponencijalnih funkcija koje se zbrajaju

α_i – vrijednost koeficijenta recesije u pojedinoj funkciji

$r(k)$ – koeficijent autokorelacije za pojedine vremenske odmake k

$x_i = (x_1, \dots, x_i, \dots, x_N)$ – vremenska serija od N podataka za koju se izračunava m koeficijenata autokorelacije $r_k = (r_0, \dots, r_k, \dots, r_m)$

x_t – ulazna vremenska serije

y_t – izlazna vremenska serije

σ_x – standardna devijacija ulazne serije

σ_y – standardna devijacija izlazne serije

MR – pronos trasera

Q – protok (m^3/s)

c ili C – koncentracija (kg/m^3)

$(Q \cdot c)$ – fluks (kg/s)

x_s – korigirana duljina transporta (m)

S – sinuositet (-)

x – pravocrtna udaljenost (m)

D_L – koeficijent longitudinalne disperzije (m^2/s),

v – efektivna brzina (m/s),

\bar{t} – centar gravitacije krivulje

t_t – srednje vrijeme prolaska trasera

δ_t^2 – varijanca krivulje koncentracije trasera

P_D – parametar disperzije (-)

α – disperzivnost (m)

D_{x_s} – koeficijent longitudinalne disperzije (m^2/s)

x_s – sinusoidalna udaljenost (m)

\bar{v} – srednja brzina (m/s)

A_p – konstanta proporcionalnosti ($kg s^{1/2} m^{-3}$)

A – površina presjeka kanala (m^2)

M – masa ubačenog trasera (kg).

C_p – maksimalna koncentracija (kg/m^3)

t_p – vrijeme maksimalne koncentracije (s)

R – faktor retardacije (-)

μ – koeficijent raspadanja prvog reda (s^{-1})

K_a – koeficijent distribucije krute i tekuće faze u kanalima (m)

r – radijus kanala (m)

C_f – koncentracija u pukotini (m^3/s)

t_0 – srednje vrijeme prolaska trasera (s)

u – varijabla integracije

M – masa trasera (kg)

a – parametar koji opisuje proces difuzije u matriks ($s^{-1/2}$)

n_p – poroznost matriksa (-)

D_p – koeficijent molekularne difuzije matriksa (m^2/s)

b – širina pukotine (m)

V – volumen mobilne vode u sustavu (m^3)

P_e – pecletov broj (-)

D – koeficijent disperzije u pukotini

D_p – koeficijent molekularne difuzije matriksa (m^2/s)

θ – volumni udio vode (-)

α – koeficijent prijenosa mase (s^{-1})

β – bezdimenzijski koeficijent udjela mobilne i nemobilne zone (maksimalni udio neravnoteže)

ω – bezdimenzijski koeficijent prijenosa mase

μ – bezdimenzijski parametar raspadanja otopine

T – bezdimenzionalna vremenska varijabla

Z – bezdimenzionalna prostorna varijabla

v_p – brzina maksimalne koncentracije

J_{relj} – gradijent reljefa (-)

dh_{relj} – visinska razlika razine trasiranog objekta i točke na terenu (m)

dl_{relj} – horizontalna udaljenost trasiranog objekta i točke na terenu (m)

Indeksi

m – mobilna zona

im – nemobilnu zonu

ad – adsorbirana faza

l – tekuća faza

1 – faza 1(uravnotežena faza)

2 – faza 2 (neuravnotežena faza)

1 UVOD

Istraživanje vode u krškim vodonosnicima u Hrvatskoj ima dugu tradiciju. Ta informacija ne čudi ako se uzme u obzir da je polovica teritorija Hrvatske prekrivena krškim naslagama i gotovo polovica stanovništva koristi za piće vodu iz krških vodonosnika. Samim time, za osiguravanje dovoljne količine pitke vode neophodno je što bolje poznavati vodonosnik i uvjete tečenja u njemu.

Kvantifikacija parametara i uvjeta tečenja u međuzrnskim vodonosnicima danas je već toliko napredovala da je uobičajena izrada diskretiziranih numeričkih modela temeljenih na poznavanju procesa (*process based models*). U slučaju krških vodonosnika izrada takvih modela je problematična radi izrazite heterogenosti i anizotropnosti.

Značajka razvijenih krških vodonosnika su disolucijski kanali često izuzetno velikih dimenzija koji dreniraju vodonosnik. Takvi kanali znatno utječu na tečenje usprkos relativno maloj mogućnosti uskladištenja vode. Brzine tečenja su u njima redovito velike i zbog toga predstavljaju najranjiviji dio krškog vodonosnika.

Pri istraživanju krša neophodno je primijeniti što više metoda, ali jedna od najkorisnijih je trasiranje. Ono ima dugu povijest i razvoj. U početku je bilo kvalitativno i služilo je isključivo za povezivanje mjesta poniranja vode i njenog ponovnog izviranja. Pri tome se dobila i gruba ideja o prividnoj brzini toka jer se otprilike izmjerilo i vrijeme potrebno da traser prevali taj put (linearna udaljenost između ulaza i izlaza). Tek se razvojem optičke elektronike dobila mogućnost mjerenja koncentracije fluorescentnih boja koje su najkorišteniji traseri (Käss, 1998), a time i mogućnost kvantitativnog trasiranja.

Razvijanjem analitike, dobila se mogućnost potpunog iskorištavanja potencijala koje nude trasiranja. Većina ovog rada posvećena je upravo detaljnoj analitičkoj obradi podataka dobivenim trasiranjem. Analizom tih podataka moguće je dobiti uvid u samu građu i svojstva krškog vodonosnika. Primjenom tih analiza u različitim hidrološkim

uvjetima mogu se uočiti promjene u njegovim svojstvima i time dobiti uvid u njegovo funkcioniranje kakav prije nije bio moguć.

Trasiranja će u ovom radu biti obrađena statističkim i analitičkim modelima te će se pomoću njih dobiti parametri toka i transporta krškim kanalima. Usporedbom rezultata nekoliko modela, moći će se procijeniti njihova primjenjivost, te dati neke smjernice i preporuke za njihovu primjenu u budućnosti.

Iako je trasiranje glavna metoda u ovom radu, niti jedno istraživanje u kršu ne može biti zadovoljavajuće izvršeno samo jednom metodom. U ovom slučaju, obrada dinamike izvora se nameće kao obavezna. Osim dobro poznatih koristi koje donosi analiza dinamike nekog sustava poput primjerice recesijske analize hidrograma izvora, dinamika je u ovom radu neophodna i jer se kvantitativno trasiranje po definiciji ne može izvršiti bez poznavanja dinamike izvora na kojem se opaža istjecanje trasera. Dakle, uspostava motrenja dinamike izvora i opažanja trasera su komplementarne i trebale bi biti sastavni dio svakog planiranog istraživanja krškog sustava u kojem je planirano trasiranje. Osim toga, kombiniranjem s motrenjem prirodnih trasera poput primjerice elektrovodljivosti mogu se dobiti vrijedne informacije.

Za provođenje trasiranja odabran je teren u jugozapadnom dijelu Žumberka koji na relativno malom prostoru sadrži pogodne aktivne ponore za trasiranje i stalne izvore Obrv i Jažu s pripadajućim krškim vodonosnicima. Napajanje izvora se odvija autogeno kroz vapnenačke i dolomitne naslage, ali i alogeno s fliškog područja. Područje je vrlo rijetko naseljeno i nalazi se pod zaštitom Parka Prirode „Žumberak-Samoborsko gorje“. Kao takvo, pogodno je kao „pilot područje“ na kojem se s prihvatljivim troškovima mogu testirati hipoteze iz ovog rada. Najveći nedostatak u smislu „pilot područja“ je dosadašnja slaba istraženost, pogotovo u hidrogeološkom smislu. Do sada se njime najdetaljnije bavila Vujnović (2010), ali u sklopu razmatranja cijelog područja Parka Prirode i to samo izvor Obrv. U sklopu njenog rada je izvršeno trasiranje dva ponora u kojem je sudjelovao i Hrvatski geološki institut, a čiji rezultati su detaljnije obrađeni u ovom radu.

Obzirom na slabo prethodno poznavanje vodonosnika Jaže i Obrva, u sklopu ovog rada su napravljena i osnovna hidrokemijska istraživanja u svrhu boljeg upoznavanja hidrogeoloških svojstava krških vodonosnika i preciznijeg razgraničenja vodonosnika izvora Jaža i Obrv.

Istraživanja koja su dovela do ovog rada su izrađena u sklopu projekta „Osnovna hidrogeološka karta Republike Hrvatske 1:100.000“ , a rezultati o hidrogeološkim značajkama će biti uklopljeni u list Novo Mesto na čijem se području nalazi teren. Metodološki rezultati bi trebali biti primijenjeni u izradi većine ostalih listova i istraživanja u kršu.

Još se može istaknuti podatak da je većina trasiranja provedena u sklopu ovog rada izvedena simultano s dva trasera. Prvo simultano trasiranje u Hrvatskoj izvedeno je na području Grobničkog polja tek 2009. godine (Kuhta et al., 2009). Prednosti simultanog trasiranja su u lakšem uspoređivanju više trasiranja jer su izvedeni u istim hidrološkim uvjetima, ali ne treba zanemariti niti financijsku stranu. Uspostavom jedne opažачke mreže pokriva se dva ili više trasiranja te je korist višestruka.

2 PREGLED DOSADAŠNJIH ISTRAŽIVANJA

Istraživano područje se nalazi na Žumberačkom gorju, u njegovom jugozapadnom dijelu.

Prvo geološko istraživanje koje ima temeljni značaj za daljnja istraživanja izvršio je Gorjanović-Kramberger (1894, 1894a) i iznio raspravu o geološkoj građi Žumberačkog i Samoborskog gorja, te dao preglednu geološku kartu područja. Pri tome je izdvojio gotovo sve naslage koje karakteriziraju geologiju tog područja.

Poznavanju geologije jugozapadnog Žumberka je znatno doprinio Herak (1947) koji se bavio raščlanjivanjem mezozojskih naslaga na tom području.

U razdoblju od 1966. do 1983. godine izrađena je Osnovna geološka karta mjerila 1:100.000 za područje Žumberka i Samoborskog gorja. U sklopu tog istraživanja je izrađen list Novo Mesto (Pleničar et al., 1975) s pripadajućim tumačem (Pleničar & Premru, 1977) koji svojim obuhvatom pokriva istraživano područje.

Novi koncept geotektonike Dinarida uveo je Herak (1986, 1990, 1991) koji je donio velike promjene u tumačenju strukturnih odnosa na Žumberku. Prihvaćanjem mobilističkog pristupa, predlaže zamjenu dviju glavnih geotektonskih jedinica (Vanjski i Unutrašnji Dinaridi) s četiri paleoambijetalna i paleodinamska pojasa. Prihvaćanjem tog pristupa, istraživano područje se nalazi u zoni kontakta dinarske karbonatne platforme – Dinarika i na nju navučenog dijela Unutrašnjih Dinarida – Supradinarika. Herak (1991) je osim toga dao puno veće značenje tangencijalnoj navlačnoj tektonici na strukturnu građu Žumberka i time doveo u pitanje tektonsku interpretaciju iz Osnovnih geoloških karata. Kao primjer takve navlačne tektonike, Herak i Bukovac (1988) su izdvojili područje tektonskog okna kod Duralija koje se nalazi na istraživanom terenu.

Hrvatski geološki institut je prvom polovicom devedesetih godina započeo novu etapu istraživanja na području Žumberka i Samoborskog gorja koja se izvode u

sklopu izrade formacijske karte Republike Hrvatske mjerila 1:50.000. Istraživanja su još u tijeku, ali dio rezultata je publiciran u geološkoj literaturi.

Bukovac i suradnici (1995) su raščlanili dolomitne naslage trijasa jugozapadnog Žumberka na tri osnovne formacije: Ruškovlje, Slapnica i Glavni dolomit s pripadajućim članovima. Grgasović (1995) je pisao o stratigrafskoj podjeli naslaga srednjeg i gornjeg trijasa, te je obrađivao biostratigrafske značajke sedimenata i alge determinirane unutar naslaga gornjeg trijasa (1997). Sokač i Grgasović (1998) su pri paleontološkoj obradi gornjotrijaskih dolomitnih naslaga otkrili novu vrstu vapnenih algi.

Obim hidrogeoloških istraživanja je bio znatno manji od geoloških istraživanja. Svi radovi vezani za istraživano područje su vezani za regionalna istraživanja. Mogu se izdvojiti Hidrogeološka karta SR Hrvatske 1:500.000 (Šarin et al., 1980), Hidrogeološka karta SR Hrvatske 1:200.000 list Celje (Hrelić et al., 1994), te projekt RGN fakulteta, Gorski i prigorski vodonosnici sjeverne Hrvatske (Dragičević et al., 1997a, 1997b) u kojem su regionalno interpretirani vodonosni potencijali i hidrogeološke značajke Žumberka.

Kao što se vidi iz prethodno navedenog, većina dosadašnjih istraživanja je regionalnog karaktera i odnosi se na puno šire područje od istraživanog u okviru disertacije. Sintezu dosadašnjih geoloških i hidrogeoloških istraživanja na području Žumberka i Samoborskog gorja su izradili Brkić i suradnici (2002). Na njihov rad, u hidrogeološkom dijelu, se nastavila Vujnović (2010) sa svojom disertacijom. U sklopu njene disertacije povremenim uzorkovanjem je praćen izvor Obrv na kojemu je istjecanje podzemne vode u okviru ove disertacije detaljno istraženo. Također je u suradnji s Hrvatskim geološkim institutom izvršeno i trasiranje ponora podno brda Štule koje je, u odnosu na disertaciju Vujnović (2010), detaljnije obrađeno u ovoj disertaciji.

3 ZNAČAJKE ŠIREG ISTRAŽIVANOG PODRUČJA

Istraživano područje se nalazi u jugozapadnom dijelu Žumberka, ali za razumijevanje geneze i građe terena, potrebno je dati kratki pregled cijelog područja. Većina radova odnosi se na Žumberak i Samoborsko gorje koje skupa čini logičnu cjelinu, a većina tog područja je zaštićena u sklopu Parka prirode „Žumberak – Samoborsko gorje“. U nastavku će ukratko biti prikazane njegove osnovne prirodne značajke.

3.1 Geografske i geomorfološke značajke

Cijelo područje se zajednički naziva Žumberačkom gorom i nalazi se u jugozapadnom dijelu Panonske nizine tj. zapadnom dijelu središnje Hrvatske. Žumberačka gora predstavlja složenu, ali jedinstvenu gorsku reljefnu cjelinu sastavljenu od Samoborskog gorja s Plešivicom i Žumberačkog gorja ili Žumberka (središnji i zapadni dio, te slovenski dio – Gorjanci) (Dujmović, 1994).

Samoborsko gorje se nalazi na istočnom dijelu i najviši vrh je Japetić visok 879 m n.m. Samo ime sugerira da se radi o nehomogenom prostoru, sastavljenom od niza različito orijentiranih gorskih blokova (Buzjak, 2006). Cijelo područje u svojevrsnom polukrugu sa sjevera i zapada obuhvaća duboka dolina Bregane. Od njenog izvorišnog područja između Brezovca Žumberačkog i Jarušja granica se pruža prema jugu, te prelazi preko planinskog bila u dolinu Žumberačke rijeke. Njome se spušta prema Petrovini, gdje prolazi Pokupskom dolinom, formirajući približan četverokut kojemu su stranice duge oko 12 km (Hirc, 1905).

U generalnom reljefu Samoborskog gorja ističe se splet brojnih planinskih grebena i potočnih jaruga u kojem je teško odrediti osnovni smjer pružanja gorja. Na reljef su osobito utjecali potoci Bregana, te Lipovečka i Rudarska Gradna, koje su svojim duboko usječenim koritima podijelile masiv u tri osnovne skupine: Plešivicu, Oštrc i Japetić.

Najviši vrh Žumberka, a ujedno i cjeline je Sveta Gera visoka 1178 m n.m. Žumberak je kao i Samoborsko gorje karakteriziran splotom gorskih grebena, vrhova i potočnih

dolina. Smjer pružanja gorja je teško odrediti, ali okosnica se donekle povija smjerom SI-JZ, a taj smjer se ne podudara niti s dinarskim, niti s alpskim smjerom pružanja (Brkić et al., 2002). Brojne su zatvorene okršene depresije (ponikve, uvale i slijepe doline). Ističu se doline rječica Kupčine, Slapnice i Sušice koje odvodnjavaju veći dio središnjeg i zapadnog Žumberka.

Područje masiva Žumberačke gore dio je megageomorfološke cjeline Panonskog bazena (Bognar, 2001). U regionalno geomorfološkom smislu, Žumberačko i Samoborsko gorje je mezogeomorfološka cjelina koja je dio makrogeomorfološke regije Gorsko – zavalskog područja sjeverozapadne Hrvatske. Orografski i morfo-genetski je jasno odijeljena od susjednih regija Krške zavale na sjeverozapadu i sjeveru, doline Save i Samoborske zavale na sjeveroistoku, zavale Crne Mlake na jugoistoku i Ozaljskog pobrđa na jugu i jugozapadu (Bognar, 2001). Unutar nje, možemo izdvojiti dvije subgeomorfološke regije: Gorski masiv Žumberačke gore i Jugoistočna predgorska stepenica. Dalje gledano unutar subgeomorfološke regije Gorskog masiva Žumberačke gore, mogu se izdvojiti mikrogeomorfološke regije: Gorski hrbat Svete Gere, Visoravan Žumberka s dolinom Kupčine (lokacija užeg područja istraživanja) i Gorski hrbat Plešivice (Dujmović, 1994).

Obzirom na strukturno-geomorfološke značajke, istraživano područje je denudacijsko – tektonska morfostruktura, podtip rasjedno – boranih sredogorskih masiva mezozojskog nabiranja heterogenog tipa (Bognar, 1980).

Teren je izgrađen pretežito od trijaskih i jurskih karbonatnih naslaga (dolomita i vapnenca) koje uvjetuju prevlast krškog i fluviokrškog reljefa. Oba tipa su dominantna u Samoborskom gorju i Žumberku iako su među njima znatne razlike u uvjetima (prvenstveno u litostratigrafskim značajkama stijena), pa time i u značajkama morfo-genetskih procesa i reljefnih oblika (Buzjak, 2006).

Doline su vrlo česti reljefni oblik nastao fluvijalnim i fluvidenudacijskim procesima, osim na područjima gdje izdaju vapnenci. Velik dio ih je tektonski predisponiran i duboko usječen duž razlomljenih zona podložnijim mehaničkom trošenju. Uglavnom su izrazitog „V“ presjeka, a neotektonsko izdizanje odvijalo se u više etapa (karakteristični „Z“ izrezi uzdužnih dolinskih profila, laktasta skretanja, asimetričnost

dolinskih strana i visinske razlike između dna i oboda dolina) (Delić, 1980; Semerl, 1979).

Buzjak (2006) je u granicama Parka prirode „Žumberak-Samoborsko gorje“ odredio 2869 ponikvi koje su prostorno neravnomjerno raspoređene. Najveću gustoću od 80 do 85 ponikvi/km² je odredio na području između Rajića, potoka Jarak i doline Slapnice gdje je gornjotrijaski glavni dolomit u kontaktu s karbonatima donje i srednje jure. Nešto niža gustoća ponikvi, od 75 do 80 ponikvi/km², zabilježena je na krškoj zaravni južno od Tisovca u trijaskim dolomitima.

Krški pojavni oblici su zastupljeni u podzemlju kao i na površini. Vujnović (2010) je navela 137 speleoloških pojava na području Parka prirode „Žumberak-Samoborsko gorje“ koje su evidentirane u vrijeme pisanja njene disertacije. Većina tih objekata je malih dimenzija, ali svejedno upućuju na vrlo intenzivne procese okršavanja karbonatnih naslaga. U vremenu pisanja ovog rada, najdulji objekt na Žumberku je spilja Provala kod Bučara s 1862 m snimljene duljine i 57 m dubine. Ona se nalazi u neposrednoj blizini istraživanih izvora, ali izvan njihovih slivova. Najdublji speleološki objekt je spilja Dolača ispod Drašćeg vrha. Njena dubina je 155 m, a duljina kanala 1171 m. Formirana je u trijaskim dolomitima koji su slabije topivi od vapnenaca, te je karakteriziraju vrlo uski i teško prohodni kanali (<http://www.speleo-klub-samobor.hr>)


3.2 Klimatološke značajke

Područje Žumberka i Samoborskog gorja pripada umjerenom klimatskom pojasu. Usprkos blizine Jadranskog mora na zapadu, utjecaj mediteranske klime je slab zbog planina Gorskog kotara koje se nalaze između. Otvorenost prema Panonskoj ravnici uvjetuje dominantni utjecaj kontinentalne klime.

Klimu po Köppenovoj podjeli možemo svrstati u klimu Cfbwx (Köppen, 1918; Vujnović, 2010). To je umjerena topla kišna klima bez suhog razdoblja (klima bukve) s toplim ljetima. Mjeseci s najmanje oborina su u hladnoj polovici godine. Tijekom godine bilježe se dva približno jednaka kišovita razdoblja, jedno je u rano ljeto, a drugo u jesen.

Izraženi reljef područja uzrokuje dodatne promjene u raspodjeli temperature zraka i oborina. Nadmorska visina generalno raste od istoka prema zapadu, te od juga prema sjeveru. U skladu s time, temperatura u istim smjerovima pada, a količina oborine raste.


Srednja godišnja temperatura zraka varira od 5°C na najvišim dijelovima Žumberka, pa do 10°C u krajnjem istočnom i južnom dijelu Žumberačkog i Samoborskog gorja (Slika 3.1). Srednja siječanjska temperatura iznosi od -1°C u najnižim dijelovima do ispod -2°C u najvišim dijelovima Žumberka. Srednja srpanjska temperatura je 20°C u najnižim dijelovima dok je u najvišim predjelima 18°C ili manje. Amplituda srednje godišnje temperature tj. razlika srednje srpanjske i srednje siječanjske temperature je oko 20°C (Brkić et al., 2002).



Slika 3.1. Karta srednje godišnje temperature zraka (prema Zaninović et al., 2004)


Srednja godišnja količina oborina je na najvećem dijelu Žumberačkog i Samoborskog gorja veća od 1000 mm. Izuzetak je jedino jug Žumberka gdje se spušta između 900 i 1000 mm. Količine oborina se generalno povećavaju s povećanjem nadmorske visine

tako da na najvišim dijelovima Žumberka padne 1500 do 1750 mm oborina godišnje (Slika 3.2).



Slika 3.2. Karta srednjih godišnjih oborina (prema Gajić-Čapka et al., 2003)

Treba spomenuti da je 2011. godina na svim mjernim stanicama Državnog hidrometeorološkog zavoda (DHMZ) na ovom području zabilježena kao rekordno sušna godina u vremenu od kada se na njima vrši mjerenje (Slika 3.3).



Slika 3.3. Srednja godišnja količina oborina na kišomjernim stanicama DHMZ-a u okolini istraživanog terena.

3.3 Osnovne geološke značajke Žumberka i Samoborskog gorja

Područje Žumberka i Samoborskog gorja karakterizirano je vrlo složenom geološkom građom. Cijeli taj prostor je kroz geološku prošlost bio izložen dinamičnim geotektonskim kretanjima koji su uzrokovali pojavu različitih taložnih okoliša i njihovu čestu promjenu, kako u vremenu tako i u prostoru. Uslijed toga, nastajale su stijene različitog petrografskog sastava i litoloških karakteristika. Aktivna tektonika dodatno je zakomplicirala strukturni sklop i geološku građu područja.

Hrvatski geološki institut je prvom polovicom devedesetih godina započeo novu etapu istraživanja na području Žumberka i Samoborskog gorja koja se izvode u sklopu izrade formacijske karte Republike Hrvatske mjerila 1:50.000. Kako su ta istraživanja još u tijeku i do trenutka pisanja ovog rada nije objavljena karta, prikaz naslaga dan je prvenstveno prema Osnovnoj geološkoj karti mjerila 1:100.000 i pripadnim tumačima (Bukovac et al., 1983; Bukovac et al., 1984; Pleničar et al., 1975; Pleničar & Premru, 1977; Šikić et al., 1977; Šikić et al., 1979).

3.3.1 Litostratigrafski pregled naslaga

Najstarije naslage na području Parka prirode „Žumberak – Samoborsko gorje“ pripada paleozojskim naslagama, dok su najrasprostranjenije mezozojske naslage, osobito trijaske starosti. Litološki prevladavaju karbonatne stijene (vapnenci i dolomiti).

Karbon, perm (C, P) – Najstarije naslage na Žumberku su nađene na profilu dužine od svega stotinjak metara koji se nalazi u sjevernom boku potoka Jaševnice kod sela Relića. Sastoje se od kvarcnih pješčenjaka i sitno znatog konglomerata s proslojcima glinenih škriljavaca.

Srednji i gornji perm (P_{2,3}) – Naslage te starosti se nalaze u dolini Rudarske Gradne i u okolici sela Poljanice Okičke, te u dolini Lipovačke Gradne kod V. Lipovca. Sastoje se uglavnom od pješčenjaka, kvarcnih konglomerata i breča koje su impregnirane željezovitim hematit – limonitnim mineralima zbog čega su tamnosive, sivosmeđe do crvenkastosmeđe boje. Unutar tih naslaga nalaze se veće ili manje leće i proslojci rudnih tijela s rudama siderita, hematita, halkopirita, pirita, galenita, sfalerita, barita te gips – anhidrita. U permskim klastitima na području Rudarske Gradne nalaze se ležišta željezne i bakrene rude koja su eksploatirana do sredine 19. stoljeća.

Permotrijas (P,T) – Ove naslage predstavljaju kraj paleozojske serije na ovom području. Nalaze se u dolini Lipovačke Gradne. Sastoje se od serija klastita raznih tipova grauvaknih i subarkoznih pješčenjaka, silita i šejlova s pojavama gipsa. U tim sedimentima nisu pronađeni fosili tako da je njihova starost određena prvenstveno superpozicijom, te litološkim i mineraloško-petrografskim značajkama. Moguće je da će budućim istraživanjima stratigrafska pripadnost tih naslaga biti promijenjena (Brkić et al., 2002).

Donji trijas (T₁) – Izdanci donjotrijaskih naslaga pojavljuju se na svega desetak relativno malih lokaliteta na području Samoborskog gorja (sjeverne padine Plešivice, Novo Selo Okičko, Braslovje, Gregurić Breg itd.), te na području Žumberka, južno od Kostanjevca. Prema novijim istraživanjima naslage donjeg trijasa su podijeljene u

dvije litostratigrafske jedinice: Konjarić Vrh donjoskitske i Ludvić gornjoskitske starosti (Avanić et al., 2000). Jedinica Konjarić Vrh je sastavljena od izmjene pješčenjaka i silita s rjeđim proslojcima vapnenca. Jedinica Ludvić je sastavljena od kalkarenita, kalsilita i vapnenca, te u manjoj mjeri proslojaka pješčenjaka.

Srednji trijas (T_2) – naslage srednjeg trijasa izdvojene su na području Cerje – Manja Vas – Konščica – Okić, na širem području Strmac – Svrževo – dolina Kupčine – potok Drenovac – Slavetić-Goljak, između Vranov Dola i Malog Lipovca, te od Ličkog potoka i doline Sopotnjaka do Lipovečke Gradne. Anizički kat je izdvojen na području Cerje – Manja Vas – Konščica – Okić i prati naslage skita. Radi se o svijetlosivim i sivim, pretežno gromadastim vapnencima, dolomitiziranim vapnencima i dolomitima. Naslage ladiničke starosti su izdvojene na području Gregurić Brega. Njihov sastav varira od cefalopodnih crvenih i sivih vapnenaca, vapnenačko – laporovitih naslaga, tamnih uslojenih vapnenaca s glinovitim ulošcima, šejlovi i piroklastiti. U njima je pronađena bogata zajednica amonita (Salopek, 1912).

Srednjetrijaske naslage na području Kostanjevca i kanjona potoka Slapnica su detaljno obrađene novijim litostratigrafskim istraživanjima (Bukovac et al, 1995). U njihovoj građi najzastupljeniji su ranodijagenetski dolomiti neformalnog naziva „Ruškovlje formacija“ debljine oko 590 metara. Unutar njih su izdvojena dva litostratigrafska člana predstavljena klastitima: naslage crvenih lapora („Berdiki član“) u donjem anizičkom dijelu, te serija silita, lapora, piroklastita i rožnjaka s vršnim dijelom od silificiranih vapnenaca i pločastih sivih vapnenaca s pojavom rožnjaka u ladiničkom dijelu („Kolići član“).

Gornji trijas (T_3) – Na području Žumberka i Samoborskog gorja ovo su najzastupljenije naslage. One pokrivaju 45,53 % Parka prirode „Žumberak – Samoborsko gorje“ (Vujnović, 2010), a nalaze se i na užem području istraživanja. Rasprostranjene su od Krke i Save na sjeveru, do linije Plešivica – Slavetić – Ruda (Mačković brdo) na jugu.

Uglavnom su izgrađene od dolomita, a taložene su u kontinuiranom i postupnom slijedu na sedimentima ladinika, te je granica najčešće tek približno locirana. Zbog otežanog odvajanja dolomita srednjeg od dolomita gornjeg trijasa, postoji mogućnost

da manji dio naslaga svrstanih u gornji trijas pripada ladiniku, odnosno srednjem trijasu. To posebno vrijedi za zapadni Žumberak obuhvaćen listom Novo Mesto Osnovne geološke karte. Na tu mogućnost upućuju sami autori karte (Pleničar et al., 1975) i tumača (Pleničar & Premru, 1977).

U starijem dijelu dolomitne serije, svijetlosive do tamnosive boje, nalazi se nekoliko metara debela zona s proslojcima tamnosivih do crnih šejlova. Dolomiti se uglavnom odlikuju izraženom laminacijom algalnog tipa. Dominantno se nalazi stromatolitni tip dolomita, a u izmjeni podređeno ima i homogenih mozaičnih dolomita ili zrnastih dolomita. U najvišem dijelu gornjotrijaskih naslaga nalazi se izmjena dolomita, sivih vapnenaca i dolomitiziranih vapnenaca. Ovaj razvoj se najljepše prati u području Vidovići – Šimraki – Tisovac. Novijim litostratigrafskim istraživanjima na području Kostanjevca i Slapnice, naslage gornjeg trijasa su podijeljene na neformalne formacije: Slapnica (s članovima Vranjak i Drenovac) debljine 340 metara, Glavni dolomit (s članom Kalje) debljine 960 metara i Posinak debljine 270 metara. Ukupna debljina gornjotrijaskih naslaga procijenjena je na 1570 metara debljine.

Karnička formacija Slapnica predstavljena je dobro uslojenim ranodijagenetskim dolomitima s ritmičnom izmjenom dolomikrita, fenestralnog dolomita i stromatolita. U donjem dijelu te formacije izdvojen je član Vranjak kojeg čine dolomiti s proslojcima šejla, dok je u gornjem dijelu iste formacije izdvojen član Drenovac. Njega čine ravno i valovito uslojeni tamni ranodijagenetski dolomiti s visokim udjelom kerogena, proslojcima kerogenskog šejla i pojavama ugljena.

Na formaciju Slapnica slijedi norička formacija Glavni dolomit. To su ranodijagenetski dolomiti s bočnom i vertikalnom izmjenom dolomikrita, fenestralnih dolomikrita, finolaminiranih stromatolita te stilolitskim slojnim plohama. U gornjem dijelu formacije uočavaju se intraformacijske breče tj. član Kalje. Retska formacija Posinak je sastavljena od dobro uslojenih ranodijagenetskih dolomita, a podređeno dolomitičnih vapnenaca i vapnenaca.

Donja jura (J₁) - Naslage donje jure zastupljene su sivim oolitnim vapnencima, brečastim vapnencima, vapnencima s rožnjacima, te bijelim zrnatim dolomitima.

Otkrivene su na malim površinama u zapadnom dijelu Žumberka, sjeverno od Tupčine i zapadno od Bojanje Vasi.

Donja i srednja jura (J_{1+2}) – Naslage donjeg i srednjeg lijasa su zastupljene plitkovodnim karbonatnim sedimentima. Nalazimo ih na većem broju lokaliteta kod Sošica, pa dalje prema zapadu sjeverno od Tomaševaca, kod Mrzlog Polja, Rajića i Vidovića, Novog Sela Žumberačkog i Osunje, te kod Koretića i Noršić Sela. Idući od zapada prema istoku primjećuje se isklinjavanje naslaga. Tako su na području Stići – Rajići – Dane – Šimraki naslage debele oko 150 metara, a sjeveroistočno na lokalitetima Gornja Pirošica, Izviri i Plešivica kod Noršić Sela svega nekoliko metara.

Najstariji dio lijasa čine dobro uslojeni dolomiti, dolomitični vapnenci i vapnenci s rijetkim foraminiferama. Kroz srednji lijas je i dalje izražena plitkovodna sedimentacija, pa se karbonatna serija sastoji od izmjene kalkarenita, biokalkarenita, oolitskih kalkarenita, biomikrita i mikrita s bogatom asocijacijom mikrofosila. Česta je dolomitizacija vapnenca.

Početak gornjeg lijasa nastupilo je razbijanje trijasko – lijaske karbonatne platforme i formiranje dubljeg bazenskog prostora. U početku se talože dolomiti i oolitični vapnenci unutar kojih se zapaža silifikacija i pojava radiolarijskih rožnjaka, a nakon toga slijede pelagički sedimenti (mikriti, biomikriti i rožnjaci). Zonalno se javljaju intrabazenske karbonatne breče (doger) iznad kojih slijede vapnenci i silificirani vapnenci s rožnjacima.

Gornja jura (J_3) – Nastavlja se sedimentacija vapnenaca s pelagičkim školjkašima i rožnjacima. Sedimenti malmske starosti izdvojeni su na temelju prve pojave vapnenačkih klastita turbiditnog porijekla unutar kontinuirane pelagičke serije. Zastupljeni su litokalkareniti, rjeđe vapnenačke breče u izmjeni s pelagičkim slojevima. Sadrže elemente plitkovodne i pelagičke sredine. Plitkovodni detritus je donasan turbiditnim strujama iz plitkovodnih i okopnjelih predjela rubnog dijela karbonatne platforme.

Naslage srednjeg malma (oksford i kimeridž) su izdvojeni oko Radatovića, a čine ih bijeli i sivi vapnenci, oolitni vapnenci i grebenski vapnenci.

U gornjem malmu (titon) na cijelom su području istaloženi pelagički sedimenti. To su uglavnom izmjene tankouslojenih pločastih pelagičkih mikrita, biomikrita i rožnjaka, a mjestimice i litokalkarenita turbiditnog porijekla, te tankih proslojaka lapora.

Donja kreda ($K_{1,2}$) – Ove naslage su sastavljene od vulkanogeno – sedimentnog kompleksa starosti apt – turon. Nalaze se na području Samoborskog gorja između Braslovja, Kotara, Manja Vasi, Konščice i Okića, te na sjevernim padinama Plešivice. Naslage su zastupljene grauvaknim pješčenjacima, šejlovima i radiolarijskim rožnjacima.

Magmatske stijene su zastupljene spilitima i dijabazima uz rijetke pojave piroklastita i vulkanskih breča.

Gornja kreda (K_2) – Naslage gornje krede su vrlo rasprostranjene na području Parka i čine 35,19 % njegove površine (Vujnović, 2010). Zastupljene su različitim litofacijsnim obilježjima.

Prvi prikaz razvoja gornjokrednih naslaga dan je prema tektonski stiješnjenom području od rijeke Krke do doline Lipovačke Gradne, te području Slapnica – Šipački Breg. U donjem dijelu su bazalne breče i konglomerati, debljine 1 do 3 metra, nastali pretaložavanjem stijena neposredne podloge. Iznad bazalnog dijela slijedi debela serija flišolikih sedimenata smeđesive do tamnosive boje u kojoj prevladavaju kalcitom i glinom bogati lapori, šejlovi i kalkareniti. S njima su u izmjeni tankopločasti vapnenci i rožnjaci, a mjestimice ima i uložaka nesortiranih karbonatnih breča. Fosilni ostaci upućuju na cenomansku starost. Slijed naslaga i lokacije nalazišta upućuju na moguću transgresiju krajem donje krede.

U tektonski izlomljenom pojasu od Novog Sela do Svete Jane i u jugozapadnom dijelu Plešivice, gornjokredni sedimenti imaju nešto drugačije litofacijsne odlike koje upućuju na kasniju transgresiju (turon? – senon). Na bazalnim sedimentima slijedi 10-20 metara uslojena izmjena vapnenačkih breča, kalkarenita, lapora i glinom bogatih vapnenaca, a rijetko i rožnjacima. Na njima prevladavaju crvenkasti, ružičasti i sivi pločasti globotrunkasti vapnenci s rožnjacima gornjosenonske starosti. Iznad njih ponovo prevladavaju karbonatni klastiti i lapori, a glinom bogati vapnenci s globotrunkanama su rijetki.

Na zapadnom dijelu Žumberka, uključujući usko istraživano područje, debljina vapnenačkih breča mjestimično doseže i 100 metara debljine. Prema OGK list Novo Mesto naslage su u normalnom tektonskom kontaktu s naslagama trijaske starosti. Prema novijim istraživanjima ustanovljeno je da je taj kontakt tektonski (Herak & Bukovac, 1988; Prtoljan, 2001; Cvetković, 2007; Molvarec, 2007; Vrsajko 2008). Na brečama slijedi vapnenac u izmjeni s laporom. Na području između sela Jezernice i Dvorišće Vivodinsko koje je također u uskom istraživanom području, izdvojen je pelagički razvoj krede vrlo sličan flišu. Devidé-Neděla et al. (1982) su tim naslagama odredili mastrihtsku starost na temelju mikrofosilnih zajednica (Globotruncanidae) i dali im naziv „Vivodinski fliš“. U njegovoj građi karbonati (vapnenci i breče) imaju značajan udio, što je uvjetovalo razvoj krških pojava i na tom području.

Litofacijski sastav gornjokrednih sedimenata u dolini Dolje na Medvednici odgovara razvojem na Žumberku i Samoborskom gorju. Obzirom na alohtonost trijaskih naslaga, može se pretpostaviti da su i kredni sedimenti zajedno s njima pomicali i dovedeni u sadašnji položaj.

Gornja krede, paleogen (K,Pg) – Sjeverno od Bojanje Vasi izdvojene su vapnenačke breče. Prema fosilnom sastavu ova breča može predstavljati najviši dio krede, ali je moguća i paleocenska starost (*Discocyclus* sp.).

Paleocen (Pc) – naslage te starosti nađene su kod Kotara i Okića u Samoborskom gorju. U bazalnom dijelu nalaze se rožnjačke breče i polimiktni konglomerati dok u pretaloženom dijelu prevladavaju rožnjaci, pješčenjaci i magmatiti iz krednog vulkanogeno – sedimentnog kompleksa, podređeno i paleozojske i trijaske stijene. Najveći dio paleocenskih sedimenata se sastoji od sivo, smeđe i crvenkastosmeđih lapora, silita i subgrauvaknih pješčenjaka unutar kojih se nalaze biokalkareniti i koraljno – algalni grebenski vapnenci. Kontinuitet na starijim sedimentima i pretaloživanje paleocenskih vapnenaca upućuje na pretpostavku da je najmlađi dio klastita taložen u gornjem paleocenu s mogućim prijelazom u donji eocen.

Gornji baden (M₄²) – Nalaze se na jugoistočnim padinama Samoborskog gorja tj. Plešivice od Podgrađa Okićkog do Prodin Dola i transgresivno leže na starijim naslagama. Sastavljene su uglavnom od breča, konglomerata, vapnenačkih

pješčenjaka, litavca, litotamnijskog vapnenca, te glinovito – pjeskovitog i kalcitom bogatog lapora. Genetski se razlikuju biogeni vapnenački sediment i klastične naslage s postojanjem terigenog materijala.

Donji sarmat (M_5^1) – Naslage donjeg sarmata nalaze se konkordantno na gornjobadenskim naslagama, a i nalazimo ih na istom području. Zastupljene su laporima, glinovitim laporima, vapnencima i pješčenjacima. U nižim dijelovima prevladavaju glinom bogati vapnenci i kalcitom bogati lapori, koji se u gornjem dijelu izmjenjuju s glinovitim laporima ili fino uslojenim listićavim laporima. Vapnenci su određeni kao biokalkareniti, oolitični kalkareniti, kalcisiltiti i pjeskovito – glinoviti vapnenci. U gornjim dijelovima naslaga donjosarmatske starosti prevladavaju dobro uslojeni laporoviti sedimenti s biljnim utruscima, koji upućuju na smirivanje unutar sedimentacijskog prostora.

Panon (M_6) – Panonske naslage nastavljaju konkordantni slijed neogenskih naslaga, pa im je i područje rasprostiranja isto. Uglavnom su razvijene kao različiti sivi, žućkasti i sivosmeđi, kalcitom ili glinom bogati lapori. Česti su tanki proslojci nevezanih, limonitiziranih, mjestimice pjeskovitih lapora. U nižim dijelovima mjestimice su dobro uslojeni ili čak laminarni, pa ih je teško odvojiti od naslaga donjeg sarmata. Mogu se naći i svijetlosivi ili gotovo bijeli pločasti glinoviti vapnenci i kalcitom bogati lapori koji su prema litološkim i paleontološkim značajkama istovjetni donjopanonskim "croatica" naslagama. Mlađi slojevi su zastupljeni laporima s većom količinom pjeskovite ili glinovite komponente.

Pliokvartar (PI,Q) - Naslage pliokvartara su na području Parka otkrivene na području zapadnog Žumberka. Sastoje se od glina s kršjem rožnjaka, a po analogiji s takvim sedimentima u okolini Krškog polja Pleničar & Premur (1977) ih svrstavaju u pliocen-pleistocen.

Kvartar (Q) – Kvartarne naslage su zastupljene u malom udjelu naspram ostalih naslaga. Najveći udio imaju holocenski potočni nanosi. Nalaze se u dolinama većih vodotoka poput Bregane, Lipovačke Gradne i Kupčine. Sastoje se uglavnom od šljunka i pijeska, a debljina im je svega nekoliko metara.

Značajno manje je zastupljena crvenica (terra rosa). Zauzima vrlo male površine formirajući površinski pokrivač promjenjive debljine ili zapunjava udubljenja i pukotine u osnovnoj karbonatnoj podlozi.

Najmanjeg rasprostiranja je sedra. Nalazi se uglavnom uz sve značajnije vodotokove, ali posebno je dobro vidljiva na Vranjačkom slapu u dolini Slapnice.


3.4 Strukturna građa i tektonika

Područje Žumberka i Samoborskog gorja karakterizirano je vrlo složenim strukturno tektonskim odnosima. Cijelo područje je prekriveno s tri lista Osnovne geološke karte, rađene u različita vremena i koristeći različite interpretacije. Posebno iskače list Novo Mesto čiji autori u interpretaciji koriste isključivo radijalnu (blokovsku) tektoniku s normalnim rasjedima bez navlačenja. Kod listova Zagreb i Črnomelj, autori koriste tangencijalne tektonske pokrete, odnosno navlačne strukturno tektonske odnose između pojedinih članova. Istraživani teren se nalazi upravo na području koje pokriva list Novo Mesto.

Za razliku od tog pristupa, po konceptu mobilističke tektonike (Herak, 1986, 1991, 1999) na području Žumberka i Samoborskog gorja dominira regionalna navlačna tektonika. Prema njemu, zapadni dio Žumberka nalazi se u kontaktnoj zoni Dinarske karbonatne platforme ili Vanjski Dinaridi (Adriaticum i Dinaricum) i Unutrašnjih Dinarida (Supradinaricum ili Najviša navlaka). Upravo u tom dijelu dolazi do podvlačenja Dinarika pod Supradinarik što uvjetuje značajne strukturno tektonske promjene u odnosu na interpretaciju s lista Novo Mesto.

Herak područje Samoborskog gorja i središnjeg dijela Žumberka do linije Konjarić Vrh – Gornji Oštrc – Sošice i dalje na zapad s vršnim grebenom do Svete Gere smatra dijelom navlake Unutrašnjih Dinarida. Jurske i kredne karbonate prekrivene transgresivnim flišem na zapadnom dijelu Žumberka smatra autohtonim područjem tj. rubnim područjem Vanjskih Dinarida. Pojava krednog fliša i jurskih vapnenaca kod sela Duralije tumači se kao tektonsko okno koje dodatno potvrđuje navlačne odnose (Herak & Bukovac, 1988).

Pamić & Tomljenović (1998) strukturno smatraju ovo graničnim područjem prijelaza Unutrašnjih Dinarida u Zagorsko – srednjetransdanubijsku smičnu zonu koja je navučena na Vanjske Dinaride. Drugi autori istu navlaku smatraju Savskom navlakom koja je kao dio Zagorsko – srednjetransdanubijske zone navučena na Vanjske Dinaride (Mioć & Pamić, 2002; Prtoljan, 2001) (Slika 3.4)




Slika 3.4. Tektonska skica predneogenske podloge u širem području jugozapadnog dijela Panonskog bazena (Šikić, 1995)

Šikić & Prelogović (1970) su na području Žumberačke i Samoborske gore izdvojili tri dominantna seta rasjeda:

- a) Set pružanja sjeverozapad – jugoistok, koji je dominantni set na području Žumberka.
- b) Set pružanja sjeveroistok – jugozapad.
- c) Set pružanja sjever – jug.

Rasjedi pružanja sjeverozapad – jugoistok su većinom reversnog pomaka. Upravo po takvim rasjedima su većinom gornjotrijaski dolomiti dovedeni strukturno iznad gornjokrednih naslaga (Prtoljan, 2001) (Slika 3.5). Pružanje tih rasjeda je paralelno s dinarskim pružanjem i kinematski korelativnim rasjedima tipičnim za područje

Vanjskih Dinarida. Obzirom na to, može se pretpostaviti istovremena aktivnost tih rasjeda tj. može se pretpostaviti tijekom paleogena. Ova interpretacija je razlog za izmjene koncepta primijenjenog na listu Novo Mesto i usvajanje rezultata novijih istraživanja (Herak, 1986, 1991; Herak & Bukovac, 1988; Prtoljan, 2001; Cvetković, 2007; Molvarec, 2007; Vrsajko, 2008).



Slika 3.5. Tektonska karta jugozapadnog Žumberka (prema Prtoljan, 2001): 1. Kvarter; 2. Neogen; 3. Gornja kreda - mastriht; 4. Donja i gornja kreda (otriv – cenoman); 5. Jura; 6. Prebačene gornjotrijaske naslage kod Duralija; 7. Gornji trijas; 8. Srednji trijas; 9. Donji trijas; 10. Čelo navlake; 11. Rasjed s horizontalnim lijevim pomakom; 12. Reversni rasjed; 13. Normalni rasjed; 14. Rasjed s označenim nagibom rasjedne plohe; 15. Pretpostavljeni rasjed; 16. Normalna i prebačena os b; 17. Normalna i transgresivna granica; 18. Normalni i prebačeni slojevi. Legenda za preglednu kartu: Ž – Žumberak; UD – unutrašnji dinaridi; JSN – julijsko-savinjska navlaka; SN – savska navlaka, ADCP – jadransko-dinaridska karbonatna platforma; ZZ – Zagreb-Zemlen rasjed; PL – Perijadranski lineament; TS - Tisia

Rasjedi pružanja sjeveroistok – jugozapad interpretirani su kao rasjedi s normalnim karakterom pomaka (Pleničar et al., 1975) ili kao rasjedi s horizontalnim lijevim pomakom (Prtoljan, 2001). Promatrano u širem geotektonskom mjerilu, ovi rasjedi pružanjem i karakterom pomaka odgovaraju tzv. balatonskom nizu rasjeda čija je aktivnost u području jugozapadnog Žumberka, kao i u području istočno od Žumberka (Hrvatsko zagorje, istočna Mađarska) interpretirana tijekom neogena i kvartara (Prtoljan, 2001; Tomljenović, 2000; Tomljenović & Csontos, 2001; Csontos & Nagymarosy, 1998). Ti rasjedi prekidaju i transliraju rasjede dinarskog pružanja. Na

području jugozapadnog Žumberka ovaj set rasjeda odvaja karbonatno – klastične sedimente mezozoika od neogenskih naslaga Karlovačkog bazena.

Rasjedi pružanja sjever – jug do sjeverozapad – jugoistok su horizontalni, ali s desnim pomakom (Šikić & Prelogović, 1970). Za razliku od prethodno opisana dva seta rasjeda, ovaj je razvijen sporadično i u manjoj mjeri. Pretpostavlja se da je njihova starost miocenska, tj. istovremena s rasjedima pružanja sjeveroistok – jugozapad. Ta dva seta čine konjugirani par čija je aktivnost povezana s istim poljem paleonaprezanja.

3.5 Hidrogeološke značajke

Vujnović (2010) je na području Parka Prirode „Žumberak – Samoborsko gorje“ izdvojila pet glavnih grupa stijena s različitim hidrogeološkim značajkama u skladu s uputama za izradu Osnovne hidrogeološke karte (Šarin, 1988):

1. Nevezane kvartarne naslage
 - a. Dobre propusnosti
 - b. Vrlo slabe propusnosti
2. Nevezane pretkvartarne naslage
 - a. Slabe propusnosti
3. Karbonatne stijene
 - a. Dobre propusnosti
 - b. Osrednje propusnosti
 - c. Slabe propusnosti
4. Izmjena klastičnih ili klastičnih i karbonatnih stijena slabe propusnosti
 - a. Slabe propusnosti
5. Klastične i magmatske stijene
 - a. Praktički nepropusne

Nevezane kvartarne naslage su predstavljene aluvijalnim potočnim nanosima i terra rosom. Terra rosa je vrlo slabe propusnosti i općenito je njeno rasprostiranje malo, te je njena uloga u hidrogeologiji područja Parka mala. Aluvijalni nanosi su u značajnim debljinama prisutni samo u prigorskim dijelovima Žumberka. Uglavnom su dobre

propusnosti, ali na području istraživanja su prisutne isključivo u aluvijalnim dolinama potoka i malih su debljina i rasprostiranja.

Nevezane pretkvartarne naslage se odnose na pliokvartarne sedimente koji se u Parku javljaju samo sporadično. Odlikuju se slabom međuzrnskom poroznosti i malog su značaja.

Karbonatne stijene čine većinu površine Parka, ali i samog istraživanog terena. Karakterizira ih pukotinska i pukotinsko – kavernozna poroznost. Propusnost im je uvjetovana litološkim sastavom i intenzitetom tektonskih deformacija.

Vujnović (2010) je pod dobro propusne svrstala tektonski razlomljene i dijelom okršene gornjotrijaske dolomite. Za te naslage su unutar Parka vezane pojave najizdašnijih izvora i njihovih vodonosnika.

Pod osrednje propusne naslage je uvrstila litotamnijske badenske vapnence, kredne vapnenačke breče, jurske vapnence i dolomite, te srednjetrijaske dolomite.


Slabo propusne karbonatne naslage predstavljene su permskim vapnencima izdvojenim u dolini potoka Lipovečka Gradna (područje Samoborskog gorja).

Izmjena klastičnih ili klastičnih i karbonatnih stijena je vezana za područja izgrađena od panonskih vapnenačkih ili glinovitih lapora, paleocenskih vapnenačkih breča i gornjokrednih „flišnih“ naslaga. Gledano u cjelini, nepropusne naslage sadržane u tim stijenama čine te naslage slabo propusnima. Međutim, vapnenačke sekvence koje se nalaze unutar njih mogu biti dobro propusne. Zahvaljujući tome, na području „Vivodinskog fliša“ postoje brojne speleološke pojave, ali i druge krške pojave poput aktivnih ponora (Brkić et al., 2002).

Magmatske i ostale klastične stijene su uglavnom nepropusne. Čine ih donjosarmatske, kredne, donjotrijaske, permotrijaske i karbonpermske stijene. Njihovo rasprostiranje na Žumberku je malo te nisu značajne.

4 ZNAČAJKE UŽEG ISTRAŽIVANOG PODRUČJA

Istraživano područje se nalazi u jugozapadnom dijelu Žumberačkog gorja (Slika 4.1). Područjem dominira brdo Štula s najvišim vrhom od 576 m n.m. Samo brdo Štula je izgrađeno od vapnenačke breče gornje krede (K_2). Vapnenačka breča je izgrađena od blokova starijih stijena koji mogu biti i većih dimenzija. Breča je jako dobro vezana te se često teško razlikuje od običnog vapnenca (Pleničar & Premru, 1977). Vujnović (2010) je po hidrogeološkim svojstvima breče svrstala u karbonatne stijene pukotinske poroznosti i osrednje propusnosti. Prema rezultatima istraživanja prezentiranim u ovom radu, gornjekredne vapnenačke breče su prebačene u skupinu karbonatnih stijena dobre propusnosti, te su tako i prikazane na hidrogeološkoj karti područja (Slika 4.1) (vidi poglavlje 8.1.6, str. 185).



Slika 4.1. Hidrogeološka karta istraživanog područja (modificirano prema Vujnović, 2010).

Zapadnu granicu brda Štula čini tektonski kontakt s flišolikim jedinicama („Vivodinski fliš“) gornje krede (K₂). Flišoliki sedimenti su smeđesive do tamnosive boje, a

sastavljeni su pretežno od kalcitičnih i glinovitih lapora, šejlova i kalkarenita. Nalaze se u izmjeni s tankopločastim vapnencima i rožnjacima, a mjestimično ima i proslojaka karbonatnih breča. Po hidrogeološkim svojstvima Vujnović (2010) ih je svrstala u stijene međuzrnske poroznosti, slabe propusnosti. Na dijelu terena prekrivenim s flišolikim naslagama postoje dva stalna površinska toka vode koji poniru na kontaktu s vapnenačkim brečama podno brda Štula. Ti ponori (P-1 i P-2) su, u okviru istraživanja za ovu disertaciju, bili mjesta ubacivanja trasera. P-1 se nalazi na nadmorskoj visini od 380 metara, dok je P-2 na nadmorskoj visini od 350 metara.

Na istočnom rubu brda Štula je navlačni kontakt naslaga gornjeg trijasa (T_3) na vapnenačke breče gornje krede. Naslage gornjeg trijasa su predstavljene Glavnim dolomitima (Hauptdolomit), a bazalni dijelovi sadrže tektonske breče i rekristalizirane vapnence i dolomite (Prtoljan, 2001). Jaka tektonika je uzrokovala dobru razlomljenost dolomita, a time i dobru propusnost (Vujnović, 2010). Dolomiti gornjeg trijasa su često vezani za dobre vodonosnike na području Žumberka, ali i kod drugih brdskih područja sjeverozapadne Hrvatske (Dragičević et al., 1997a). Gornjotrijaski dolomiti su dobro okršeni tako da u njima nalazimo i speleološke objekte. Na samom istraživanom terenu, praktički u samom selu Gornji Oštrc, nalazi se Jamina pod Piskom. Radi se o jami dubokoj svega 10 metara koja je poslužila kao mjesto ubacivanja boje prilikom jednog trasiranja izvedenog za potrebe ovih istraživanja.

Blizu kontakta breča gornje krede i dolomita gornjeg trijasa, nalaze se stalni izvori Obrv i Jaža koji zajedno tvore potok Jaševnicu. Izvori su međusobno udaljeni samo 200 metara, a oba su otprilike na nadmorskoj visini od 240 metara. Vrlo su sličnog kapaciteta i dinamike. Prijašnji podaci o dinamici postoje jedino za Obrv i odnose se na mjesečna mjerenja u razdoblju od veljače 2008. do veljače 2009. godine. Tada je minimalni protok bio 7,5 l/s, a maksimalni protok 262 l/s. Omjer minimalnih, srednjih i maksimalnih voda je bio $Q_{\min} : Q_{\text{sred}} : Q_{\max} = 1 : 8 : 35$ (Vujnović, 2010).

Kontinuiranim mjerenjima razina u sklopu izrade ovog rada (poglavlje 5.1, str. 28), omjer minimalnih, srednjih i maksimalnih voda na Jaži je bio $Q_{\min} : Q_{\text{sred}} : Q_{\max} = 1 : 33 : 2716$. Najmanji protok je bio 2 l/s dok je najveći bio 5432 l/s (najveći neposredno izmjereni je 1011 l/s). Na Obrvu je ustanovljen omjer $Q_{\min} : Q_{\text{sred}} : Q_{\max} = 1 : 10 : 320$.

Minimalni protok iznosi 4,5 l/s dok je maksimalni bio 1445 l/s (maksimalni neposredno izmjereni je 577 l/s).

Površine slivova izvora Jaža i Obrv su izračunati pomoću količine oborina s najbliže kišomjerne stanice Vivodina koja je smještena na području istraživanja. Obzirom na relativno malu površinu slivova, u obzir nisu uzete ostale kišomjerne stanice na području Žumberka radi velike udaljenosti. Za dobivanje efektivne količine oborina koja je relevantna za bilancu vode, korišten je koeficijent otjecanja. Iznos koeficijenta otjecanja za ovo područje su računali Dragičević et al. (1997a) i Vujnović (2010). Njihovi koeficijenti otjecanja iznose 0,41 (za sliv Kupčine) tj. 0,38 (za Park Prirode „Žumberak – Samoborsko gorje“). Oba koeficijenta su vrlo slična, ali za potrebe ovog rada je uzet koeficijent otjecanja 0,38 prema Vujnović (2010) jer su korišteni noviji podaci. Uzevši u obzir količinu oborina na stanicama u Vivodinama, te protoke na Jaži i Obrvu u 2011. i 2012. godini, površine pripadajućih slivova su procijenjene na 5,5 km² za izvor Jaža i 3,7 km² za izvor Obrv.

Granice slivova prikazane na Slika 4.1 određene su na temelju rezultata istraživanja provedenih u sklopu izrade disertacije.

5 DINAMIKA PODZEMNOG SUSTAVA

Krški vodonosnici se odlikuju velikom heterogenošću hidrogeoloških svojstava uzrokovanom nepravilnom mrežom pukotina i kanala. One mogu biti milimetarskih do metarskih dimenzija. Brzina vode u kanalima može biti i 1000 puta veća od brzine unutar mreže pukotina (Droge, 1980).

Istraživanje prostornog rasporeda i svojstava pukotinskog i kanalnog sustava je skup, dugotrajan, a često i nemoguć proces. Radi toga su determinističke metode istraživanja krških vodonosnika, koje zahtijevaju poznavanje prostornih značajki sustava, relativno rijetke. Puno zastupljenije su vjerojatnosne metode koje se zasnivaju na proučavanju odnosa ulaznih (napajanje vodonosnika) i izlaznih parametara (istjecanje na izvoru).


Iako je trasiranje podzemnih voda glavna metoda u ovom radu, dinamika podzemnog sustava, posebno izvora, mora biti neizostavni dio istraživanja jednog krškog vodonosnika. Već sam uvid u kapacitete izvora može dati značajan uvid u funkcioniranje vodonosnika koji ga napaja. Osim toga, za izvođenje kvantitativnih trasiranja kakva su izvedena u ovom radu, neophodno je poznavanje količine protoka na mjestima istjecanja trasera.

5.1 Opis metoda i mjesta uspostave opažanja

Kontinuirano mjerenje razine, temperature i elektrolitičke vodljivosti vode uspostavljeno je na izvorima Jaža i Obrv, te ponorima P-1 i P-2, dok je povremeno mjerenje razine i temperature vode bilo uspostavljeno na izvoru Studena (Slika 4.1, str. 25).

Mjerenja su ostvarena pomoću automatskih mjerača s internom memorijom, tzv. *logera*. Za praćenje svih navedenih parametara korištena su dva logera po lokaciji, oba proizvođača Hobo. Oba logera mjere temperaturu, dok jedan mjeri razinu vode pomoću barometarskog tlaka, drugi mjeri elektrolitičku vodljivost. Za dobivanje razine vode iz barometarskog tlaka s logera, potrebno je napraviti kompenzaciju s

atmosferskim tlakom. Atmosferski tlak je također mjeren loggerom proizvođača Hobo. Obzirom na relativno malo područje, korišten je samo jedan za kompenzaciju svih logera u izvorima i ponorima. Logeri su postavljeni u perforirane metalne cijevi kako bi se zaštitili (Slika 5.1).



Slika 5.1. Način postavljanja logera na opažane izvore i ponore

Cijev s loggerima na izvoru Obrv je postavljena otprilike 30 metara od samog izvora. Sami izvor je često posjećivan, pa se na taj način pokušala smanjiti mogućnost vandalizma. U slučaju izvora Jaža, logeri su postavljeni desetak metara od samog izvora, na prvom mjestu s prikladnom dubinom vode. Treba napomenuti da se 50-ak metara istočno od glavnog izvora, nalazi još jedan manji izvor. Mjerenjem fizikalno – kemijskih parametara vode, te koncentracije trasera tijekom trasiranja, ustanovljeno je da se radi o istoj vodi koja izvire na glavnom izvoru. To je zapravo bazni tok Jaže čiji je protok ograničen veličinom kanala. U njemu je također bio postavljen logger za


razinu, ali zbog vrlo malog kolebanja razine, za protočnu krivulju su korišteni podaci s glavnog izvora Jaže s kojim je hidraulički povezan.

Logeri su postavljeni i u blizini ponora P-1 i P-2. Kod oba ponora, radi se zapravo o skupini ponora koji se aktiviraju pri različitim hidrološkim uvjetima, postoji glavni ponor koji je stalno aktivan. Kod ponora P-1 logeri su postavljeni u poniruću potok otprilike 30 metara prije glavnog ponora.


U slučaju ponora P-2, logeri su prvotno postavljeni neposredno prije glavnog ponora u korito ponirućeg potoka. Nakon nekog vremena, voda je probila novi put kroz nanos i gotovo u potpunosti zaobišla logere. Radi toga su logeri 27.7.2011. godine premješteni otprilike 50 metara uzvodno gdje su ostali do kraja motrenja.

Ponori se nalaze u krškim uvalama koje povremeno poplave tijekom visokih voda. Obzirom na to, i slijevanje vode s više strana u uvale, nije bilo moguće napraviti protočne krivulje za visoke razine.

Razine vode izvora su pretvorene u protoke pomoću protočne krivulje koja je konstruirana pomoću dvadesetak mjerenja protoka (Slika 5.2 i Slika 5.3). Protoci su mjereni u svim hidrološkim uvjetima. Mjerenje je ovisno o hidrološkim uvjetima izvođeno pomoću hidrometrijskog krila proizvođača Seba i Global Waters za vrijeme niskih voda, te tijekom visokih voda pomoću ADCP (*Acoustic Doppler Current Profiler*) StreamPro uređaja tvrtke Teledyne RD Instruments (Slika 5.4).



Slika 5.2. Protočna krivulja za izvor Jaža.



Slika 5.3. Protočna krivulja za izvor Obrv.



Slika 5.4. a – ADCP uređaj za mjerenje protoka; b – mjerenje protoka ADCP uređajem na izvoru Jaža

Na području istraživanja (Slika 4.1, str. 25) su postavljena dva kišomjera RG3-M proizvođača Hobo (Slika 5.5). Kišomjeri sadrže automatski logger koji bilježi količinu oborine te njezin intenzitet. Kišomjer bilježi točno vrijeme svakih 0,2 mm kiše po m². Obzirom na veliku rezoluciju, ti podaci su korišteni za analize vremenskih serija (poglavlje 5.2.5). Konstrukcija kišomjera uzrokuje podcjenjivanje količine oborina prilikom jakih kiša, te ne može zadovoljavajuće mjeriti oborine u obliku snijega. Radi toga su za potrebe izrade bilance korištene količine oborina sa DHMZ-ove kišomjerne stanice Vivodina (poglavlje 4).



Slika 5.5. Kišomjer RG3-M proizvođača Hobo

5.2 Metode analiza

5.2.1 Analiza hidrograma

Hidrogram krškog izvora je osnovni vremenski niz podataka u analizama hidrogeoloških značajki krških vodonosnih sustava. On predstavlja izravni zbirni odraz svih fizikalnih procesa koji utječu na tečenje podzemne vode unutar krškog vodonosnika. Tipičan hidrogram krškog izvora ima izrazite i nagle promjene protoka u vremenu (Bonacci, 1987, 1993; Goldscheider & Drew, 2007). Takve nagle promjene su posljedica postojanja vrlo propusnih sustava pukotina i kanala koji su sposobni u vrlo kratkom vremenu transportirati oborinsku vodu do izvora. Osim sustava visoke hidrauličke vodljivosti, postoji i slabije propusna stijenska masa zaslužna za postojanje baznog toka (Atkinson, 1977; Mangin, 1975; Padilla et al., 1994).

Hidrogrami izvora predstavljaju odaziv složenog sustava, te je za njihovu interpretaciju korisno pratiti i fizikalno – kemijske značajke vode (temperatura, elektrolitička vodljivost, mutnoća i dr.). Svaka promjena uvjeta istjecanja i protoka je praćena i promjenom svojstava vode. Ukoliko se uz protok kontinuirano prate i

svojstva vode, može se dobiti značajno kvalitetniji uvid u sam vodonosnik i njegovo funkcioniranje.

5.2.1.1 Recesijska analiza hidrograma

Recesijska analiza je analiza padajućeg dijela hidrograma. Recesijske krivulje najčešće pokazuju samo dio dinamičkih rezervi vodonosnika ovisnih o početnim razinama vode. Ukupan volumen vode u vodonosniku može biti puno veći.

Recesijska analiza može se bazirati na analizi pojedinih vodnih valova (Drogue, 1972; Mangin, 1975; Atkinson, 1977; Milanović, 1981; Bonacci, 1987, 1993; i drugi), ali i statističkoj obradi cjelovitih hidrograma višegodišnjih nizova podataka (Mangin, 1984; Padilla & Pulido-Bosch, 1995; Larocque et al., 1998; i drugi).

Recesijsku krivulju bi idealno bilo konstruirati na vrlo dugom recesijskom razdoblju bez značajnijih oborina. Tada recesijska krivulja može dati dobar uvid u strukturne značajke vodonosnika. Oblik krivulje ovisi o različitim faktorima među kojima su najvažniji tip poroznosti, hidrološki uvjeti tj. razina vodnog lica, te udio napajanja iz drugih vodonosnika. Oborine pale za vrijeme recesije otežavaju analizu jer uzrokuju promjenu recesijske krivulje na istom izvoru. Iz tog razloga je definiranje značajki vodonosnika na temelju jednog recesijskog razdoblja nesigurno.

Istraživanja recesije hidrograma izvora i površinskih tokova su stara više od stoljeća. Prvu recesijsku analizu na izvorima je pokušao napraviti Boussinesq (1877, 1904) pomoću modela pražnjenja otvorenog primarno poroznog vodonosnika. Pražnjenje sustava izrazio je kvadratnom funkcijom jednadžbe recesije oblika hiperbole:

$$Q_t = \frac{Q_0}{[1 + \alpha_r(t - t_{poč})]^2} \quad (5-1)$$

gdje je,

α_r – koeficijent recesije (dan^{-1})

Q_0 – protok na početku recesije u vrijeme $t_{poč}$ (m^3/s)

Q_t – protok u nekom vremenu t (m^3/s)


Maillet (1905) je došao do jednadžbe recesije proučavajući recesije hidrograma površinskih tokova. Njegovo rješenje je eksponencijalna formula:

$$Q_t = Q_0 e^{-\alpha_r t} \quad (5-2)$$

Eksponencijalna formula približno opisuje desaturiranje vodonosnika konstantne površine uz uvjet laminarnog toka (Urumović et al., 2009). Ukoliko se krivulja recesije dobivena Mailletovom formulom prikaže na log – normalnom mjerilu, dobije se pravac nagiba α_r . Eksponencijalna jednadžba je dijelom i zbog svoje jednostavnosti do danas ostala najčešće korištena za prognozu minimalnih protoka u slučaju dugotrajnih suša iako rijetko opisuje cijeli recesijski događaj (Dewandel et al., 2003). Koeficijent recesije α_r karakterizira brzinu odvodnjavanja vodonosnika i neovisan je o apsolutnim protocima na izvoru. Radi te osobine je pogodan za usporedbu različitih vodonosnika bez obzira na razlike u ukupnim izdašnostima pojedinih izvora.

Pražnjenje vodonosnika se rijetko odvija po jednoj jednadžbi recesije tj. jednom koeficijentu recesije α_r . Obično tijekom pražnjenja vodonosnika imamo dva ili više

mikrorežima pražnjenja, svaki sa svojim koeficijentom recesije (Slika 5.6).



Slika 5.6. Krivulje recesije jednostavnog sustava pražnjenja (A) i složenog sustava pražnjenja (B); slučaj linearnog sustava (C) i odgovarajuće krivulje recesije (D) (prema Bonacci, 1987)


Veličina koeficijenta recesije ukazuje na različita hidrogeološka svojstva vodonosnika, a ovisi o transmisivnosti i o specifičnom uskladištenju. Koeficijent recesije $\alpha_r > 10^{-2}$ upućuje na brzo dreniranje kroz velike pukotine i kanale, dok $\alpha_r < 10^{-2}$ ukazuje na sporo dreniranje vode iz manjih pora i pukotina, tj. dominaciju

stijenskog matriksa u toku vode kroz krško podzemlje (Krešić, 1997). Pomoću koeficijenta recesije možemo također izračunati volumen vode uskladištene u vodonosniku koji će gravitacijski isteći tijekom recesije tj. dinamičke rezerve.

$$\alpha_r = \frac{Q_t}{V_t} \quad (5-3)$$

Gdje je Q_t količina istjecanja u vremenu t , a V_t volumen uskladištene vode iznad razine izvora (Krešić, 1997).

U slučaju više mikrorežima pražnjenja vodonosnika, sumiraju se volumeni pojedinih mikrorežima tj. pripadajućih koeficijenata recesije (Slika 5.7).



Slika 5.7. Shematski prikaz recesije s tri mikrorežima pražnjenja vodonosnika i odgovarajućih volumena vode (prema Krešić, 1997).

Ukupni volumen za primjer s tri mikrorežima se računa pomoću izraza:

$$V_t = V_1 + V_2 + V_3 = \left[\frac{Q_1}{\alpha_{r1}} + \frac{Q_2}{\alpha_{r2}} + \frac{Q_3}{\alpha_{r3}} \right] 86400 \quad (5-4)$$

Mnogi su autori predložili složenu eksponencijalnu formulu u svrhu boljeg opisivanja ukupne recesije krškog izvora (Forkasiewicz & Paloc, 1967; Milanović, 1981; Bonacci, 1987, 1993; i drugi):










$$Q_t = \sum_{i=1}^N Q_{0i} e^{-\alpha_{ri} t} \quad (5-5)$$

u kojoj N predstavlja broj eksponencijalnih funkcija koje se zbrajaju, a α_{ri} je vrijednost koeficijenta recesije u pojedinoj funkciji. Jedno pražnjenje krškog vodonosnika najčešće opisuje zbroj tri eksponencijalne funkcije s pripadajućim koeficijentima recesije α_{r1} , α_{r2} i α_{r3} . Svaki koeficijent recesije opisuje vrstu poroznosti u krškom vodonosniku. Koeficijent α_1 odražava značajke krških kanala, koeficijent α_{r2} značajke propusnijih pukotina, a koeficijent α_{r3} značajke slabo propusnih pukotina i primarno propusnog matriksa. Koeficijenti se obično međusobno razlikuju za jedan red veličine.

Eisenlohr et al. (1997a) i Kovács (2003) su pomoću računalnog modela tokova vode analizirali pouzdanost tumačenja tro-komponentnog hidrograma izvora. Njihov model se sastojao od dvije komponente: provodni kanali i slabije propusna sredina oko njih. Rezultat modela je bila simulirana recesija koja se mogla prikazati zbrojem tri eksponencijalne funkcije recesije. Iz tog pokusa proizlazi da tri recesijske krivulje ne znače nužno i tri hidraulički različite sredine u vodonosniku. Koeficijent recesije α_2 može biti odraz fenomena prijelaznih tokova iz slabije propusnih volumena u provodne kanale.

Do danas su brojni autori pokušali doći do jednadžbe koja bi najbolje opisala recesijski dio hidrograma (Tablica 5.1), ali najčešće jedna jednadžba nije u stanju opisati cijeli recesijski period.

Tablica 5.1. Pregled metoda analize recesijskih dijelova hidrograma (prema Dewandel et al., 2003)

Metoda	Model	Formula	Egzaktno rješenje	Približno rješenje	Matematički prikladno
Boussinesq (1877)		$Q_t = Q_0 e^{-\alpha_r t}$ $Q_0 = (\pi/2) K H l (h_m / L)$ $\alpha_r = \pi^2 K H / 4 \phi L^2$		X	
Maillet (1905)		$Q_t = Q_0 e^{-\alpha_r t}$		X	
Boussinesq (1903)		$Q_t = Q_0 / (1 + \alpha_r t)^2$ $Q_0 = 1.724 K h_m^2 l / L$ $\alpha_r = 1.115 K h_m / \phi L^2$	X		
Schoeller (1948) Barnes (1939)		$Q_t = \sum_{i=1}^n Q_{0_i} e^{-\alpha_{r_i} t}$			X
Horton (1933)		$Q_t = Q_0 e^{-\alpha_r t^m}$			X
Coutagne (1948)		$Q_t = Q_0 [1 + (n-1) \alpha_{r0} t]^{n/(1-n)}$ $\alpha_{r_t} = \alpha_{r0} [1 + (n-1) \alpha_{r0} t]^{-1}$			X
Droge (1972)		$Q_t = Q_0 / (1 + \alpha_r t)^n$			X
Mangin (1975)		$\psi(t) = q_0 / (1 - \eta t / 1 + \epsilon t)$ $\phi(t) = q_{r0} e^{-\alpha_r t}$		X	X
Padilla et al. (1994)		$Q_t = (Q_0 - Q_c) [1 + (n-1) \alpha_{r0} t]^{n/(1-n)} + Q_c$			X
Samani & Ebrahimi (1994)		$\theta_t = (Q_0 - q_c) [1 + (n-1) \alpha_{r0} t]^{n/(1-n)}$ $\phi(t) = q_0 e^{-\alpha_r t}$		X	X


5.2.1.2 Konstrukcija glavne recesijske krivulje (GRK)

Ukoliko opažanje izvora traje dovoljno dugo vremena, u vremenskom nizu podataka može se izdvojiti veći broj recesijskih razdoblja. Na oblik i nagib recesijskih krivulja utječu mnogi faktori poput prostornog i vremenskog rasporeda oborina, evapotranspiracija, klimatološki uvjeti, brzina napajanja itd. Uslijed svih tih faktora, recesijske krivulje za različita razdoblja će se razlikovati u manjoj ili većoj mjeri. Izdvajanje jedne recesijske krivulje u tom slučaju može dovesti do pogrešnih zaključaka o vodonosniku. Za uvažavanje svih raspoloživih podataka o recesijama i uvjeta pod kojima su se odvijali, te smanjivanje mogućnosti pogrešnog odabira, razvijena je glavna recesijska krivulja. Za njenu konstrukciju najčešće se koriste dvije metode preklapanja recesijskih krivulja: „matching strip“ (Snyder, 1939) i korelacijska metoda (Langbein, 1938). „Matching strip“ metoda je uklopljena u Visual Basic (VB) makro unutar MS Excel softvera i potpuno automatizirana (Posavec et al., 2006). Makro može koristiti algoritme pet različitih linearnih i nelinearnih modela regresije (linearni, logaritamski, polinom drugog reda i *power* – funkcija opće potencije). Glavna krivulja se konstruira po najboljem modelu, koji se bira po kriteriju najvišeg koeficijenta determinacije R^2 . Završni odabir je moguće vizualno provjeriti jer visok koeficijent determinacije nije garancija za najbolji model (Riggs, 1968). Obzirom da se krivulja recesije krških izvora najčešće treba simulirati s dvije ili više jednadžbi recesije, izrađen je i program za automatsku podjelu glavne krivulje recesije (Posavec et al., 2010; Parlov, 2010). Primarna podjela se bazira na krivulji trajanja srednjih dnevnih protoka na kojoj se mjesta podjele biraju određivanjem kritičnih protoka kod kojih dolazi do promjene nagiba krivulje trajanja.

5.2.2 Analiza recesije na izvorima Jaža i Obrv


Dobivanje glavne recesijske krivulje Jaže i Obrva ishodišno je pokušano korištenjem VB Makroa „matching strip“ metodom koristeći srednje dnevne protoke za cijelo opažano razdoblje (20.12.2010. – 12.01.2013.). Brzi odaziv oba izvora na oborine uzrokuje pojavu strmih krivulja pražnjenja u praktički bilo kojem dijelu hidrograma. Takve strme krivulje ukazuju na prisustvo vrlo propusnih sustava pukotina i kanala koji oborine vrlo brzo dreniraju i dovode do izvora. Uslijed takvih uvjeta istjecanja,

automatska metoda dobivanja recesijske krivulje nije dala zadovoljavajuće rezultate (Slika 5.8). Rezultirajuća glavna krivulja recesije pokušava uprosječiti sve recesije koje su radi brzog toka loše postavljene.




Slika 5.8. Pokušaj dobivanja glavne krivulje recesije izvora Jaže „matchig strip“ metodom

Obzirom da se pomoću automatske metode nije uspjela izdvojiti kvalitetna jedna glavna krivulja recesije, izdvojeni su pojedinačni recesijski dijelovi. Recesije su izdvojene na način da na njima nema izraženih nepravilnosti i prekida recesije izazvane infiltracijom novih oborina (Slika 5.9 i Slika 5.10).




Slika 5.9. Izdvojeni periodi recesije na izvoru Jaža. Pored recesije je napisan koeficijent recesije



Slika 5.10. Izdvojeni periodi recesije na izvoru Obrv. Pored recesije je napisan koeficijent recesije


Na tako izdvojenim recesijskim dijelovima ponovljena je „matching strip“ metoda za oba izvora (Slika 5.11 i Slika 5.12).

Izvor Jaža je najbolje opisan s dvije glavne krivulje recesije. Vrijednost koeficijenta recesije prve krivulje iznosi $\alpha_{r1} = 0,0749 \text{ dan}^{-1}$ s koeficijentom determinacije $R^2 = 0,98$. Druga krivulja recesije ima koeficijent recesije $\alpha_{r2} = 0,0567 \text{ dan}^{-1}$ s koeficijentom determinacije $R^2 = 0,93$.



Slika 5.11. Glavna recesijska krivulja izvora Jaža dobivena „matching strip“ metodom na prethodno odabranim recesijskim dijelovima.

U slučaju izvora Obrv, cijela krivulja recesije je vrlo dobro opisana samo jednom glavnom krivuljom recesije. Njen koeficijent recesije je $\alpha_r = 0,074 \text{ dan}^{-1}$ s koeficijentom determinacije $R^2 = 0,98$



Slika 5.12. Glavna recesijska krivulja izvora Obrv dobivena „matching strip“ metodom na prethodno odabranim recesijskim dijelovima.

Pomoću dobivenih koeficijenata recesije možemo izračunati dinamičke rezerve vodonosnika za bilo koje vrijeme tj. protok na izvoru (unutar valjanosti recesijske krivulje) pomoću izraza (5-3) odnosno (5-4). Volumeni za vodonosnike Jaže i Obrva su izračunati za vrijednosti njihovog srednjeg protoka u razdoblju od 1.1.2011. do 31.12.2012. godine.


U slučaju Jaže, srednji dnevni protok je 63 l/s, a volumen iznosi 86 495 m³.

Srednji dnevni protok Obrva je 43 l/s, a pripadajući volumen 50 205 m³.

Prilikom interpretacije podataka dobivenih pomoću krivulje recesije treba napomenuti da je niz od dvije godine, korišten prilikom ove analize, prekratak za donošenje čvrstih zaključaka o funkcioniranju tih vodonosnika.

5.2.3 Analiza hidrograma i kemograma izvora

Karakteristična značajka krških izvora je brz odaziv na napajanje vodonosnika uslijed jakih oborina, tzv. *storm evenata*. Prilikom takvih događaja, promjena na protoku izvora obično nastupa prije promjene fizikalno – kemijskih značajki vode. Povećanje hidrauličkog tlaka uslijed dolaska nove vode se gotovo trenutačno (brzinom zvuka u vodi tj. ~1500 m/s) prenosi kroz saturirane dijelove kanala do izvora, puno brže od same vode (Bezes, 1976; Drogue, 1967; Ford & Williams, 1989). Promjena fizikalno – kemijskih značajki slijedi tek nakon što sama infiltrirana voda dopiše do izvora. Razlika u vremenu između promjene (povećanja) protoka i promjene fizikalno – kemijskih značajki vode odgovara vremenu prolaska svježe infiltrirane vode kroz freatske kanale (Slika 5.13). Pomoću tog vremena moguće je procijeniti volumen freatskih kanala ukoliko znamo protok na izvoru (Atkinson, 1977; Sauter, 1992; Ryan & Meiman, 1996). Procijenjeni volumen bi trebalo smatrati kao gornju granicu stvarnog volumena, jer može uključivati volumen iz drugih dijelova krškog sustava, kao primjerice epikršku zonu iznad vodnog lica (Williams, 1983) ili uskladištenje iz dubokog vodonosnika (Desmarais & Rojstaczer, 2002).




Slika 5.13. Dvije hidraulički različite faze toka: vodni val i recesijski tok. Svaka faza odgovara različitom funkcioniranju sustava. Nijansa plave boje odražava rast ili pad koncentracije na izvoru kao funkcija protoka (prema Grasso and Jeannin, 2002).

Promjena fizikalno – kemijskih značajki vode se odražava kroz količinu otopljenih iona. Uslijed brzog transporta vode kanalima tijekom *storm evenata*, voda ne dolazi u stanje kemijske ravnoteže kao što je u slučaju „stare“ vode. U karbonatnim vodama obično se uzima Ca^{2+} , ali pošto su promjene nagle, uzorkovanje vode je obično prerijetko. U tu svrhu koncentracija Ca^{2+} iona se može zamijeniti s elektrolitičkom vodljivošću i temperaturom vode koju možemo mjeriti kontinuirano (Birk et al., 2003; Dreiss, 1989; White, 2002). Pri tome se za krajnje točke uzimaju točke najbrže promjene parametara (Ashton, 1966). Volumen freatskih kanala se dobiva integriranjem volumena vode koja je istekla na izvoru od trenutka početka povećanja protoka, pa do trenutka najveće promjene fizikalno – kemijskih karakteristika vode.

5.2.4 Analiza vodnih valova pomoću hidrograma i kemograma na izvorima Jaža i Obrv

Analiza vodnih valova pomoću hidrograma i kemograma provedena je na izvorima Jaža i Obrv za cijelo razdoblje opažanja dinamike. Iako su od kontinuiranih fizikalno – kemijskih parametara vode bili raspoloživi temperatura i elektrolitička vodljivost, za analize oba izvora je korištena jedino elektrolitička vodljivost (specifična elektrolitička vodljivost) (Slika 5.14) jer je pokazivala oštrije promjene. Vodni valovi na kojima promjena elektrolitičke vodljivosti i temperature nisu bili jasni nisu uključeni u analize.




Slika 5.14. Isječak hidrograma izvora Jaža sa Specifičnom elektrolitičkom vodljivošću. posebno su označeni vodni valovi za čijeg trajanja je izmjeren volumen vode koji predstavlja volumen freatskih kanala u datim uvjetima.

Tablica 5.2 sadrži volumene freatskih kanala i vrijeme trajanja istjecanja „stare“ vode za sve provedene analize.


Tablica 5.2. Rezultati analiza odaziva izvora Jaže i Obrva na nailazak vodnih valova

izvor Jaža			izvor Obrv		
Datum	Trajanje (sati)	Volumen (m ³)	Datum	Trajanje (sati)	Volumen (m ³)
22.12.2010	21	18.822,95	21.12.2010	17	5.554,40
7.1.2011	21	17.789,92	7.1.2011	11	3.369,10
16.3.2011	13	14.479,37	16.3.2011	10	1.887,40
28.3.2011	12	14.576,17	28.3.2011	9	2.045,40
25.4.2011	24	14.232,18	4.4.2011	16	3.093,20
28.7.2011	7	5.674,57	12.4.2011	15	3.209,50
20.10.2011	12	3.298,99	14.6.2011	8	1.856,30
26.10.2011	5	141,04	28.7.2011	17	2.912,80
15.12.2011	46	3.083,16	20.10.2011	22	3.166,60
2.1.2012	28	1.444,91	26.10.2011	19	4.076,20
24.1.2012	11	453,00	17.12.2011	12	3.849,40
5.4.2012	9	335,39	3.1.2012	30	2.490,90
8.4.2012	6	810,46	24.2.2012	17	3.256,30
23.5.2012	8	12.326,80	5.4.2012	38	3.596,80
1.9.2012	2	59,46	8.4.2012	20	4.020,20
6.9.2012	4	77,20	22.5.2012	13	2.885,10
13.9.2012	3	61,61	23.5.2012	7	3.802,40
19.9.2012	12	14.402,81	5.6.2012	5	613,30
16.10.2012	10	18.597,92	12.6.2012	8	3.986,70
27.10.2012	25	13.116,65	1.9.2012	6	728,70
31.10.2012	17	18.618,62	19.9.2012	9	4.254,40
5.11.2012	12	14.299,75	1.10.2012	17	8.835,00
12.11.2012	17	13.090,22	15.10.2012	10	6.738,91
28.11.2012	23	9.553,83	27.10.2012	23	7.993,68
4.12.2012	11	9.141,76	31.10.2012	10	7.712,69
14.12.2012	22	12.934,34	5.11.2012	10	7.006,30
26.12.2012	12	14.896,22	12.11.2012	13	7.083,28
Prosjek:	14,56	9.122,94	29.11.2012	5	8.228,92
Minimalni:	2	59,46	15.12.2012	16	7.235,72
Maksimalni:	46	18.822,95	25.12.2012	13	4.672,50
			26.12.2012	8	4.839,11
			Prosjek	14,00	4.354,88
			Minimalni:	5	613,30
			Maksimalni:	38	8.835,00

Slika 5.15 i Slika 5.16 prikazuju hidrograme izvora Jaže odnosno Obrva za cijelo razdoblje motrenja skupa s izračunatim volumenima freatskih kanala. Na hidrogramu su obilježeni vodni valovi tj. njihovi dijelovi pomoću kojih su izračunati volumeni.



Slika 5.15. Volumeni freatskih kanala izvora Jaža i hidrogram s naznačenim vodnim valovima na temelju kojih su napravljeni proračuni.



Slika 5.16. Volumeni freatskih kanala izvora Obrv i hidrogram s naznačenim vodnim valovima na temelju kojih su napravljeni proračuni.

5.2.5 Analiza vremenskih serija

Pored analiziranja pojedinih događaja ili samo recesijskih dijelova hidrograma, mogu se analizirati i kompletni hidrogrami statističkom obradom vremenskih nizova podataka. Većinu matematičkih metoda razvili su Jenkins & Watts (1968) i Box & Jenkins (1974). Prvi ih je u hidrogeologiji krša primijenio Mangin (1981, 1984), a Padilla & Pulido-Bosch (1995) su ih dodatno razvili.

Analizom vremenskih serija mogu se odrediti svojstva krških sustava, ispitati ovisnosti protoka na izvoru i oborina na pojedinim kišomjernim stanicama, ispitati zavisnosti protoka s drugim fizikalno – kemijskim parametrima te ispitati međusobnu ovisnost protoka na više izvora. Razlikujemo univarijatne analize koje služe za analizu značajki i strukture jedne vremenske serije (autokorelacija) i bivarijatne analize koje analiziraju vezu ulazne i izlazne vremenske serije (kroskorelacija). Osnovni preduvjet za primjenu ovih metoda je postojanje neprekinutih vremenskih nizova mjerenih u istim vremenskim intervalima.

5.2.5.1 Autokorelacijska funkcija

Autokorelacijska funkcija definira linearnu ovisnost sukcesivnih vrijednosti podataka unutar vremenskog niza ovisno o njihovom vremenskom odmaku (Box & Jenkins, 1974; Stroj, 2007). Metoda se temelji na uspoređivanju vremenske serije same sa sobom uz diskretno povećanje vremenskog odmaka, pri čemu se računa koeficijent autokorelacija $r(k)$ za pojedine vremenske odmake k prema izrazu:

$$r(k) = \frac{C(k)}{C(0)} \quad (5-6)$$

$$C(0) = \frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2 \quad (5-7)$$

$$C(k) = \frac{1}{N} \sum_{i=1}^{N-k} (x_i - \bar{x}) (x_{i+k} - \bar{x}) \quad (5-8)$$

U izrazima (5-5 do 5-7) $x_i = (x_1, \dots, x_i, \dots, x_N)$ predstavlja vremensku seriju od N podataka za koju se izračunava m koeficijenata autokorelacije $r_k = (r_0, \dots, r_k, \dots, r_m)$. Preporuča se

da vrijednost m ne prelazi $N/2$ (Box & Jenkins, 1974), odnosno $N/3$ (Mangin, 1984). Grafički prikaz r_k vrijednosti za pojedine vremenske odmake prikazuje se korelogramom i pokazuje karakter, intenzitet okršenosti i retencijske sposobnosti vodonosnika. Mangin (1984) vrijeme potrebno da vrijednost r_k padne ispod 0.2 naziva „efekt memorije“ koji odražava trajanje reakcije sustava na ulazni impuls. Duži memorijski učinak ukazuje na slabo razvijenu mrežu krških kanala i veću retencijsku sposobnost krškog sustava, dok kratkotrajni odražava malu retencijsku sposobnost sustava s gustom i dobro povezanom mrežom provodnih kanala. Treba spomenuti da su Grasso & Jeannin (1994) i Eisenlohr et al. (1997b) dokazali da oblik korelograma ne ovisi samo o značajkama krškog sustava, nego i o intenzitetu, trajanju i učestalosti oborina te pri njegovoj interpretaciji treba biti oprezan.

5.2.5.2 Kroskorelacijska funkcija

Kroskorelacijska funkcija definira linearnu zavisnost ulazne x_t i izlazne y_t vremenske serije ovisno o njihovom vremenskom odmaku, slično kao što autokorelacijska funkcija uspoređuje jedan vremenski niz sam sa sobom. Koeficijent kroskorelacije računa se u skladu s time slično kao koeficijent autokorelacije prema sljedećem izrazu:

$$r_{xy}(k) = \frac{c_{xy}(k)}{\sigma_x \sigma_y} \quad (5-9)$$

$$c_{xy}(k) = \frac{1}{N} \sum_{i=1}^{N-k} (x_i - \bar{x})(y_{i+k} - \bar{y}) \quad (5-10)$$


a σ_x i σ_y standardne devijacije ulazne i izlazne serije. Ako je ulazna serija slučajna, tada kroskorelacijska funkcija $r_{xy}(k)$ predstavlja reakciju sustava na ulazni impuls. U drugim slučajevima $r_{xy}(k)$ odražava vezu ulazne i izlazne serije, kao i značajnost te veze. Kroskorelacijska funkcija nije simetrična [$r_{xy}(k) \neq r_{yx}(k)$], te ako je $k < 0$, u jednadžbama (5-8) i (5-9) x zamjenjuje y i obratno. Ako je $r_{xy}(k) > 0$ za $k > 0$ izlazna serija je zavisna o ulaznoj, a ako je $r_{xy}(k) < 0$ za $k > 0$ ulazna je zavisna o izlaznoj. Simetrična kroskorelacijska funkcija sa centrom simetrije u $k = 0$ ukazuje da su i ulazna i izlazna serija ovisne o nekoj trećoj seriji uz istovremene odgovore, te da ulaz

ne utječe na izlaz. Vrijeme kašnjenja izlazne funkcije za ulaznom definira vremenski odmak k kod maksimalne vrijednosti $r_{yx}(k)$ (Stroj, 2010). Nulta vrijednost vremenskog odmaka ($k = 0$) obično se nalazi na početku obiju vremenskih serija. Koeficijenti kroskorelacije se prikazuju grafički na kroskorelogramu s odgovarajućim vremenskim odmacima.

5.2.5.3 Odnosi vremenskih serija na izvorima Jaža i Obrv


Analize vremenskih serija su provedene na protocima izvora Jaža i Obrv, podacima oborina na postavljenim kišomjerima, te podacima s ponora P-1 i P-2. Treba naglasiti da su sve vremenske serije u trajanju od otprilike dvije godine što nije dovoljno dugačko vremensko razdoblje za definiranje pouzdanih zaključaka o njihovim odnosima. Ipak, čak i takvi relativno kratki nizovi mogu dati uvid u funkcioniranje krških vodonosnika izvora Jaže i Obrva. Obzirom na malu veličinu slivova i brzi odaziv izvora na oborine, za analize su korišteni satni podaci.

Autokorelacijska analiza izvora Jaža ukazuje na dominantni brzi tok i praktički izostajanje baznog toka. Strmi nagib funkcije tj. trajanje brzog toka je prosječno u promatranom razdoblju bilo 54 sata što se ujedno poklapa s vrijednosti $r(k) = 0,2$ tj. „memorijskim efektom“ (Slika 5.17). Tako kratki odaziv na oborine ukazuje na vrlo okršenu sredinu s vrlo niskom sposobnosti retencije vode.




Slika 5.17. Autokorelacijska funkcija izvora Jaža

Kod izvora Obrv situacija je nešto drukčija, ali i kod njega je dominantni brzi tok (Slika 5.18). Strmi dio krivulje tj. trajanje brzog toka je otprilike 60 sati. U slučaju Obrva autokorelacijska funkcija ukazuje na postojanje baznog toka koji je i kod njega prilično kratak. Iako je vrijednost $r(k) = 0,2$ tek nakon nešto više od 21 dana, mjerodavna vrijednost bi ipak bila malo manje od deset dana gdje se $r(k)$ spušta blizu vrijednosti od 0,2, ali se onda opet diže. Uzrok ponovnom dizanju je vjerojatno ponavljanje vodnih valova u otprilike sličnim ciklusima.




Slika 5.18. Autokorelacijska funkcija izvora Obrv

Kroskorelacijska analiza Jaže i Obrva pokazuje neovisnost jednog o drugom i visoki stupanj korelacije u maksimalnom iznosu 0,906 (Slika 5.19). Također se može uočiti minimalno kašnjenje Jaže za Obrvom u trajanju do jednog sata. Obzirom da je učestalost mjerenja svakih sat vremena, tako malo zaostajanje se može smatrati zanemarivim tj. izvori reagiraju gotovo istovremeno.




Slika 5.19. Kroskorelacijska funkcija izvora Jaža i Obrv

Kroskorelacijskom analizom je napravljena usporedba protoka na izvorima Jaža i Obrv te količine oborina na kišomjernim postajama u Gornjem Oštrcu i Dančulovićima (Slika 4.1, str. 25). Dobiveni maksimalni koeficijenti korelacije od 0,218 do 0,252 su prilično niski, ali usprkos tome pokazuju vezu između oborina i protoka na izvorima (Slika 5.20). Prosječno kašnjenje Jaže za oborinama mjerenima na Dančulovićima je 8 do 9 sati. U slučaju Obrva, kašnjenje za oborinama na području G. Oštrca je 9 do 10 sati u prosjeku. Treba napomenuti da oborine na području G. Oštrca kasne na oborine u području Dančulovića otprilike jedan sat. Istraživanjima u sklopu izrade disertacije utvrđeno je da se izvor Jaža napaja s područja kojeg pokriva kišomjer na Dančulovićima, dok kišomjer u G. Oštrcu pokriva područje napajanja izvora Obrv. Iz tog razloga je prikazana kroskorelacija svakog izvora samo sa pripadajućim kišomjerom.



Slika 5.20. Kroskorelacijska funkcija izvora Jaža i Obrv s oborinama na lokacijama Dančulovići i G. Oštrc

Obzirom na dokazanu vezu između ponora P-1 i P-2 s izvorom Jaža, na njima je napravljena kroskorelacijska analiza (Slika 5.21). Obzirom da je uvjet za izvođenje analize neprekinuti slijed podataka s jednakom učestalošću prikupljanja, dinamika ponora je morala biti zastupljena s razinama umjesto s protocima koje je nemoguće odrediti u uvjetima visokih voda. Usprkos tome, maksimalni koeficijent korelacije je visokih 0,9 odnosno 0,815. Pri tome je prosječno kašnjenje Jaže za ponorom P-1 od nula do 2 sata, dok je za ponorom P-2 od 1 do 3 sata.



Slika 5.21. Kroskorelacijska funkcija protoka na izvoru Jaža i razina vode na ponorima P-1 i P-2

6 HIDROGEOKEMIJSKA SVOJSTVA VODE

6.1 Metode i tehnike mjerenja

Uzorci vode su uzimani iz izvora Jaža i Obrv, te iz ponora P-1 i P-2 u razdoblju između 6.10.2010. i 6.12.2012. godine. Uzorci su uzimani u razmacima od otprilike mjesec dana. Prilikom uzorkovanja, *in situ* su mjereni fizikalno – kemijski parametri vode koji su posebno osjetljivi na promjene uvjeta okoliša, te ih je nužno izmjeriti na samom terenu. Mjereni su elektrolitička vodljivost, temperatura, pH, i sadržaj kisika. Parametri su mjereni sondama proizvođača WTW.


U uzorcima vode analiziranim u laboratoriju mjereni su Osnovni kationi i anioni. Koncentracije natrija, kalija, magnezija i kalcija su mjerene metodom atomske apsorpcije pomoću AAS Analyst 700 instrumenta, proizvođača Perkin – Elmer. Koncentracije nitrata, ortofosfata, sulfata i klorida su mjerene metodom ionske kromatografije pomoću ionskog kromatografa proizvođača LabAlliance i kolone tvrtke WARTEX. Hidrogenkarbonatni ioni su mjereni titrimetrijskom metodom.

6.2 Metode obrade rezultata mjerenja

Podaci fizikalno – kemijskih pokazatelja sustavno mjerenih na terenu, kao i podaci hidrokemijskih laboratorijskih analiza, obrađeni su geokemijskim modeliranjem pomoću računalnog programa NETPATH (Plummer et al., 1994). Program se bazira na geokemijskom modelu ravnoteže masa, a sastoji se od nizova manjih potprograma koji omogućuju unošenje i uređivanje kemijskih podataka o analiziranim vodama, računanje indeksa zasićenosti pojedinih minerala (npr. kalcita, dolomita) u vodama, parcijalnih tlakova plinova (npr. CO₂) i pojedinih otopljenih spojeva prisutnih u vodi. Pomoću programa se može izvršiti interpretacija modela miješanja različitih voda na način da se utvrđuje u kolikoj količini pojedine (početne) vode utječu na formiranje završne (krajnje) vode.


6.3 Obrada rezultata mjerenja

Osnovna podjela po kemijskom sastavu svrstala je vode iz izvora Jaža Ca-HCO₃ tipu voda tj. hidrokemijskom facijesu (Slika 6.1). Takav facijes ukazuje na dominantno otapanje kalcita iz vapnenačkih stijena.




Slika 6.1. Piperov dijagram izvorskih voda Jaže

Voda izvora Obrv pripada Ca-HCO₃ do CaMg-HCO₃ tipu voda ovisno o hidrološkim uvjetima, ali i drugim utjecajima (Slika 6.2). Osnovni kemijski sastav je posljedica otapanja karbonatnih minerala, s tim da u slučaju izvora Obrv, osim utjecaja otapanja kalcita, znatan utjecaj ima otapanje dolomita.




Slika 6.2. Piperov dijagram izvorskih voda Obrva

Vode koje poniru na ponorima P-1 i P-2 radi sličnog kemijskog sastava možemo prikazati skupa na jednom Piperovom dijagramu (Slika 6.3). Voda koja na njima ponire pripada Ca-HCO₃ tipu voda tj. otopljeni minerali su pretežno porijeklom iz vapnenca.




Slika 6.3. Piperov dijagram ponirućih voda ponora P-1 i P-2

Kod izvora Jaža i ponora dominantni otopljeni ion je kalcij, ali povremeno se može primijetiti nešto veći sadržaj magnezija (Slika 6.4 – područje označeno narančastom elipsom). Takva veća količina otopljenog magnezija pretežno je vezana za razdoblja niskih voda (Slika 6.5).




Slika 6.4. Odnos koncentracije magnezija i $n(Mg^{2+})/n(Ca^{2+})$



Slika 6.5. Molarni odnos magnezija i kalcija u ovisnosti o protoku na izvoru Jaža


Istovremeno s povećanjem magnezija dolazi i do blagog povećanja kalija (Slika 6.6), pa se može zaključiti da porijeklo magnezija nije dolomit nego alumosilikatne stijene, porijeklom vjerojatno iz fliša. Uslijed niskih voda, brzina tečenja je mala, pa dolazi do nešto većeg otapanja teže topivih silikatnih minerala. Dodatni povoljni faktor su nešto veće temperature vode jer je razdoblje niskih voda vezano pretežno za topla ljetna razdoblja, a dio vode izvora Jaža dolazi s površinskih tokova koji tekü po flišu, pa je radi toga i temperatura vode veća.



Slika 6.6. Odnos koncentracije magnezija $n(\text{Mg}^{2+})/n(\text{K}^{+})$ na izvoru Jaža


U slučaju vode s izvora Obrv, pretežno je prisutan utjecaj dolomita (Slika 6.4 – plavi četverokut), ali u nešto podređenijem dijelu raste utjecaj kalcita (Slika 6.4 – plava elipsa). Ako udio magnezija usporedimo s hidrološkim uvjetima na izvoru (Slika 6.7), možemo primijetiti da udio magnezija generalno raste tijekom trajnijih recesijskih razdoblja. Uzrok tome je vjerojatno dulje zadržavanje vode u podzemlju i otapanje dolomita, ali moguće i napajanje izvora u većem udjelu iz dolomitnog dijela vodonosnika. Treba napomenuti da je odnos protoka i udjela magnezija dosta nepravilan i sadrži brojne iznimke. Udio magnezija očigledno ne ovisi samo o trenutnim hidrološkim uvjetima na izvoru nego i o brojnim drugim čimbenicima poput

učestalosti i prostorne raspodjele oborina i prethodnim uvjetima tečenja različitim dijelovima vodonosnika.



Slika 6.7. Molarni odnos magnezija i kalcija u ovisnosti o protoku na izvoru Obrv

Sličan zaključak se može dobiti ako promotrimo model miješanja za izvor Obrv (Slika 6.8). Tijekom niskih voda dominantan je utjecaj dolomita. S porastom količine vode na izvoru, generalno raste i količina vode porijeklom iz vapnenca, ali zavisnost je prilično neodređena i postoje iznimke od tog pravila. Usprkos tome, može se primijetiti da je tijekom duljeg razdoblja recesije, pražnjenje pretežno iz dolomitnog dijela vodonosnika.



Slika 6.8. Model miješanja za vode izvora Obrv

Treba napomenuti da je izrađen model miješanja vode vapnenačkog i dolomitnog porijekla za izvor Jaža, ali je pokazala da je voda isključivo vapnenačkog porijekla, odnosno nema dolomitnog utjecaja. To je potvrda i rezultata trasiranja tj. ne postojanje veze dolomitnog vodonosnika i izvora Jaže.

7 KVANTITATIVNA TRASIRANJA

Primarni cilj hidrogeoloških istraživanja je određivanje porijekla, kretanja i odredišta podzemne vode. U krškim vodonosnicima je to posebno težak zadatak radi izrazite heterogenosti. Vjerojatno najučinkovitija metoda u kršu za ispunjavanje tog zadatka je trasiranje.

Najjednostavnije je kvalitativno trasiranje pri kojem se utvrđuje postojanje veze između točke ubacivanja trasera i opažanih lokacija. Ovisno o gustoći i načinu uzorkovanja, moguće je dobiti i okvirne prividne brzine tečenja. Prisutnost trasera na opažanoj lokaciji može se određivati kvantitativno (npr. koncentracijom), ali i ne mora (npr. vizualno kod fluorescentnih boja). Kvalitativno trasiranje je trenutno najzastupljeniji način trasiranja u Hrvatskoj.

Puno više informacija o vodonosniku se može dobiti pomoću kvantitativnog trasiranja. Preduvjet da bi trasiranje mogli smatrati kvantitativnim je izrada bilance trasera tj. usporedba količine trasera koja je ubačena u sustav i količine trasera koju smo detektirali na izlazu iz sustava (Field, 2002). Primjenjujući tu metodu dobivamo uvid u količine trasera na opažanim točkama. Na taj način možemo ocijeniti gubitak trasera i uspješnost trasiranja. Detaljnijim obrađivanjem takvih podataka moguće je dobiti određene parametre vodonosnika potrebne za procjenu transporta zagađenja (Field & Nash, 1997).

Posebno korisna su simultana trasiranja. Izvode se ubacivanjem dva ili više trasera na različitim lokacijama u isto vrijeme. Na taj način smo sigurni da su trasiranja izvedena u istim hidrološkim uvjetima, pa možemo donositi točnije zaključke o vodonosniku. Vrlo značajna je i financijska korist jer u sklopu jednog opažanja dobivamo rezultate za više trasiranja. Prilikom planiranja simultanog trasiranja mora se paziti na odabir trasera. Njihova svojstva se moraju dovoljno razlikovati da bi ih mogli razlikovati u slučaju istovremene pojave u istom uzorku. Prvo simultano trasiranje u Hrvatskoj izvedeno je na području Grobničkog polja tek 2009. godine (Kuhta et al., 2009).

U sklopu izrade disertacije izvedeno je ukupno deset trasiranja. Prva dva trasiranja izvedena su simultano u suradnji s dr.sc. Tatjanom Vujnović za potrebe izrade njene disertacije. Trasirani objekti su bili ponori P-1 i P-2. Trasiranje na ponoru P-2 nije uzeto u obzir u ovoj disertaciji radi gubitka dva ključna uzorka vode s traserom (Vujnović, 2010).

Ponori P-1 i P-2 su nakon toga uzastopno trasirani u različitim hidrološkim uvjetima ukupno sedam puta. Ponor P-1 četiri puta i ponor P-2 tri puta. Jedno trasiranje je izvedeno u jami Jamina kod Piska.


Ponori P-1 i P-2 su trasirani simultano u tri navrata. Trasiranje Jamine pod Piskom je izvedeno dva dana prije trasiranja ponora P-1 u hidrološki mirnom periodu, pa se i ta dva trasiranja mogu smatrati simultanim.

7.1 Metodologija kvantitativnog trasiranja

Cilj kvantitativnog trasiranja je dobivanje informacija o dinamici tečenja vode u podzemlju. Za izvođenje kvantitativnog trasiranja nužno je izmjeriti količinu trasera na izlazu iz sustava koju onda možemo usporediti s ubačenom količinom trasera u sustav (Field, 2002). Da bi se to postiglo, potrebno je imati dovoljnu gustoću vrijednosti o koncentraciji trasera na izlazu iz sustava (izvoru) i podatke o protoku.

Krivulja koncentracije trasera (Slika 7.1) je osnovni izvor informacija dobiven trasiranjem. Njen oblik ovisi o (Smart, 1988a):

- značajkama trasera
- Prevladavajućim uvjetima tečenja
- Svojstvima vodonosnika



Slika 7.1. Primjer krivulje koncentracije trasea i njenih tipičnih elemenata: t_1 = vrijeme prvog nailaska, t_p = vrijeme maksimalne koncentracije, C_p = pik (maksimum) koncentracije, $t(R/2)$ = vrijeme kada je polovica detektiranog trasea prošla kroz mjesto opažanja, t_m (ADM) = srednje vrijeme dobiveno modelom advekcije-disperzije (Goldscheider et al., 2008).

Izborom odgovarajućeg trasea, određivanjem uvjeta tečenja i razumijevanjem regionalne hidrogeologije možemo izvući zaključke o svojstvima jednostavnih vodonosnika.

Informacije o sustavu možemo dobiti numeričkom analizom krivulje koncentracije trasea. Iz tog razloga je potrebno da ona bude dobro pokrivena s uzorkovanjima. Prerijetko uzorkovanje može dovesti do drastičnih razlika u krivulji i posljedično pogrešnom interpretacijom (Smart, 1988a). U slučaju prerijetkog uzorkovanja ili završetka uzorkovanja prije isteka kompletnog trasea, moguće je interpolirati tj. ekstrapolirati krivulju. Prilikom toga treba biti oprezan jer bilo kakve promjene uvjeta istjecanja u tom periodu neće biti adekvatno prikazane.

7.1.1 Izračun pronosa

Pronos (M_R) izražava količinu trasera koja je izmjerena na opažanim lokacijama. Može biti izražena apsolutno kao masa ili relativno kao postotak od ukupno ubačenog trasera. Da bi izračunali pronos, osim krivulje koncentracije trasera trebamo imati i podatke o istovremenom protoku na opažanim lokacijama. U slučaju konstantnog protoka, pronos je jednak umnošku površine ispod krivulje trasera i protoka. U slučaju da protok nije konstantan, sve vrijednosti koncentracije moraju biti pomnožene s odgovarajućim protokom da bi dobili fluks, a pronos je jednak površini ispod krivulje fluksa. Općenita jednadžba je:

$$MR = \int_{t=0}^{\infty} (Q * c) dt \quad (7-1)$$

Gdje je Q = protok (m^3/s), c = koncentracija (kg/m^3), $(Q*c)$ = fluks (kg/s) i t = vrijeme (s).

U praksi, taj proračun se najčešće radi dijeljenjem krivulje na kolone (širina = period uzorkovanja) i sumiranjem u nekoj proračunskoj tablici.

Pomoću pronosa možemo procijeniti pouzdanost trasiranja, ali i tip podzemne mreže kanala (Goldscheider & Drew, 2007).

7.1.2 Procjena hidrauličkih i geometrijskih parametara kanala

Postoje dva načina dobivanja osnovnih hidrauličkih i geometrijskih parametara podzemnih kanala u kršu. Jedan je fizičko ulaženje u podzemlje i izvršavanje izravnih mjerenja. Taj pristup nije uvijek dostupan i gotovo uvijek je ograničen na mali dio postojećih kanala. Drugi pristup je kvantitativno trasiranje tj. numerička analiza krivulje koncentracije trasera pomoću koje možemo dobiti zadovoljavajuće procjene većine parametara. Uvjet je da smo svjesni ograničenja ulaznih podataka (Field & Pinsky, 2000). Pod ograničenjima se smatraju greške u mjerenjima protoka, podcijenjena udaljenost transporta, neodgovarajući raspored uzorkovanja (Mull et al., 1988, Smart, 1988b; Field & Nash, 1997).

Podatke o parametrima kanala pomoću trasiranja dobivamo modeliranjem. Ovisno o primijenjenom modelu mogu se razlikovati parametri koje ćemo dobiti, ali uvijek postoje dva osnovna: disperzija i srednja efektivna brzina toka (advekcija). U nekim slučajevima izlazni parametri su i sorpcija te koeficijent raspadanja prvog reda. Radi pojednostavljenja modela i smanjivanja višeznačnosti rješenja, obično se pretpostavlja da je traser konzervativan.

Srednja efektivna brzina toka predstavlja brzinu dobivenu pomoću srednjeg vremena prolaska trasera kroz vodonosnik i udaljenosti. Ona predstavlja brzinu centra mase trasera kroz vodonosnik. U nekim slučajevima se srednja brzina izjednačava s brzinom maksimalne koncentracije. Što više je tečenje u podudarnosti s Fickovim zakonom to će srednja brzina biti sličnija brzini maksimalne koncentracije. U realnosti, srednja brzina je redovito manja od brzine maksimalne koncentracije. Uobičajena je praksa iskazivati brzinu prve pojave trasera. Ona nema fizikalnu osnovu i u najvećoj mjeri ovisi o osjetljivosti opreme za detekciju trasera i gustoći opažanja. Srednja efektivna brzina pruža puno više informacija o funkcioniranju vodonosnika i hidrauličkim svojstvima kanala (Field, 2002).

Obzirom da su svi modeli primijenjeni u ovom radu jednodimenzionalni, pod disperzijom se misli isključivo na longitudinalnu disperziju. Koeficijent longitudinalne disperzije je mjera brzine kojom se koncentrirana masa trasera proširi duž putanje kojom putuje (Mull et al., 1988). Definirana je kao promjena varijance oblaka trasera u vremenu (Fisher, 1968). Važna je za analizu krških kanala jer pruža uvid u moguće širenje zagađivala.

Topivi ne reaktivni traser (primjerice neke fluorescentne boje) ubačen u tok vode ponaša se poput samih čestica vode. Zahvaljujući tome, mjera kretanja trasera i njegove značajke disperzije, odgovarati će mjeri kretanja elementa fluida u toku (Kilpatrick & Wilson, 1989).

Ulazni podaci u model su podaci o izvedenom trasiranju i protok na opažanim lokacijama. Osnovni podatak o trasiranju je krivulja koncentracije trasera s početkom od vremena ubacivanja trasera. Osim krivulje potrebno je znati količinu ubačenog trasera te duljinu transporta.

Osim u rijetkim slučajevima kada su kanali speleološki istraženi prava duljina transporta je nepoznata. Tada je kao duljinu transporta moguće uzeti pravocrtnu udaljenost mjesta ubacivanja i mjesta opažanja trasera. S obzirom da je posve sigurno da ta duljina ne odgovara stvarnosti, uobičajena je praksa pravocrtnu duljinu pomnožiti sa sinuositetom (Palmer, 2007; Field & Nash, 1997; Worthington, 1991, Sweeting, 1973).

$$x_s = x \cdot S \quad (7-2)$$


Gdje je x_s = korigirana duljina transporta (m), x = pravocrtna duljina transporta (m), S = sinuositet (-).

Sinuositet je moguće izračunati poznavanjem pravih duljina speleoloških objekata i njihove pravocrtnu duljinu. U slučaju da na istraživanom području nema dovoljno speleoloških objekata može se uzeti prosjek koji je dobiven na temelju velikog broja speleoloških objekata diljem svijeta, a kreće se u rasponu od 1,2 do 1,8, pa se obično uzima 1,5 (Palmer, 2007; Field & Nash, 1997). I takva vrijednost se treba smatrati grubom procjenom koja može značajno odudarati od stvarnosti.

U ovom radu je za proračune parametara trasiranja korištena udaljenost korigirana za sinuositet. Za njegovu vrijednost je uzeta prosječna vrijednost od 1,5. Zaštita krških izvorišta u Republici Hrvatskoj definirana je Pravilnikom o utvrđivanju zona sanitarne zaštite izvorišta (NN 55/02, NN 66/11, NN 47/13) u kojoj je prividna brzina podzemne vode ključni faktor za određivanje stupnja zaštite nekog područja u kršu. Usprkos tome, definicija prividne brzine i metodologija njezinog određivanja nije definirana. Praksa do sada je bila kao referentnu uzimati prividnu brzinu prvog nailaska trasera i to određenu preko pravocrtnu udaljenosti. Radi toga će se u ovom radu izračunati isključivo brzina prvog nailaska s pravocrtnom udaljenošću kako bi se mogla lakše usporediti s rezultatima ostalih trasiranja na ovim prostorima.

Ubacivanje trasera može biti trenutačno ili obavljeno u nekom vremenskom periodu. Ukoliko je ubacivanje trajalo, treba znati točno trajanje ubacivanja i početnu koncentraciju trasera. Prilikom izbora modela treba paziti da je model predviđen za takav način ubacivanja boje.

Za razliku od međuzrnskih vodonosnika gdje se najčešće primjenjuju diskretizirani modeli, u kršu se radi velike heterogenosti i anizotropije primjenjuju uglavnom globalni modeli. Princip funkcioniranja globalnih modela je pretvaranje podataka o ulazu u sustav u podatke o izlazu iz sustava pomoću analitičkih jednažbi koje predstavljaju fizikalna svojstva sustava (Goldscheider & Drew, 2007). Fizikalne parametre sustava dobivamo inverznim modeliranjem tj. koristimo poznati izlaz iz sustava za dobivanje njegovih fizikalnih parametara. To se obično postiže usporedbom stvarnog i modeliranog izlaza. Parametri se podešavaju do zadovoljavajućeg preklapanja modelirane krivulje i izmjerene krivulje (Slika 7.2). Dobiveni parametri se onda mogu koristiti za predviđanje unaprijed.



Slika 7.2. Usporedba mjerene krivulje koncentracije trasera (puna linija) s rezultatima različitih kalibriranih modela (Birk et al., 2005)

Analitička rješenja za modeliranje se baziraju na jednažbama transporta. Za advektivno – disperzivni transport potrebno je dobiti dva parametra, advekciju i disperziju. Advekcija predstavlja širenje trasera samim tokom vode. Disperzija

uzrokuje razrjeđenje trasera koje je najveće u smjeru toka – longitudinalna disperzija. Za razrjeđivanje trasera odgovorna je i molekularna difuzija tj. kretanje trasera radi gradijenta koncentracije (Fickov zakon). U krškim kanalima molekularna difuzija ima zanemariv iznos u odnosu na advekciju i disperziju. Najjednostavniji primjer jednadžbe jednodimenzionalnog transporta konzervativnog trasera je (Bear, 1979):

$$\frac{\partial C}{\partial t} = D_L \frac{\partial^2 C}{\partial x^2} - v \frac{\partial C}{\partial x} \quad (7-3)$$

Gdje je C = koncentracija (kg/m^3), t = vrijeme (s), D_L = koeficijent longitudinalne disperzije (m^2/s), v = efektivna brzina (m/s), x = udaljenost (m).

Moguća analitička rješenja te jednadžbe su mnogobrojna, a ovise o početnim i rubnim uvjetima. Rezultat toga je postojanje mnogobrojnih modela. Izbor modela koji će se koristiti ovisi o konceptualnom modelu istraživnog područja, kvaliteti ulaznih podataka te potrebama istraživanja. Niti jedan model ne može objasniti sve krivulje koncentracije trasera. Prilikom modeliranja neophodno je kritički prihvatiti procjene parametara.

7.1.3 Modeli za procjenu hidrauličkih parametara

S obzirom na veliki broj postojećih modela od kojih mnogi nisu primjereni istraživanju u kršu, izbor detaljnije prikazanih modela biti će ograničen samo na one koji su korišteni u izradi disertacije.

U obzir su uzeti samo oni modeli koji su do sada uspješno upotrebljavani u kršu. Svaki model zastupa drukčiji konceptualni model širenja trasera kroz krški kanal. Neki modeli su uključeni u jedan ili više računalnih programa koji olakšavaju postupak modeliranja.

Za sva ubacivanja trasera tijekom izrade disertacije smatra se da su trenutačna te se neće razmatrati modeli za postepena ubacivanja trasera. Svi razmatrani modeli su jednodimenzionalni.

7.1.3.1 Metoda momenata s Chatwinovom metodom

Za procjenu transporta konzervativnog trasea često je korištena statistička metoda momenata (Field, 2002, Kreft & Zuber, 1978). Pomoću nje se mogu dobiti procjene efektivne brzine trasea i disperzije pomoću centra mase i vremenske varijance dobivene iz krivulje trasea. Metoda je uklopljena u softver QTRACER2 koji je korišten pri izradi disertacije (Field, 2002)

Nulti moment služi dobivanju pronosa. Prvim i drugim momentom dobivaju se matematički deskriptori (Field, 2002; Leibundgut et al., 2009):

- 1) centar gravitacije krivulje \bar{t} koji predstavlja srednje vrijeme prolaska trasea t_t

$$\bar{t} = t_t = \frac{\int_0^{\infty} tC(t)dt}{\int_0^{\infty} C(t)dt} \quad (7-4)$$

- 2) varijanca krivulje koncentracije trasea δ_t^2

$$\delta_t^2 = \frac{\int_0^{\infty} (t-\bar{t})^2 C(t)dt}{\int_0^{\infty} C(t)dt} \quad (7-5)$$

Pomoću koje se može dobiti parametar disperzije P_D (-) tj. disperzivnost α (m) jednačbama:

$$P_D = \frac{1}{2} \left(\frac{\delta_t}{\bar{t}} \right)^2 \quad (7-6)$$

ili

$$\alpha = \frac{x}{2} \left(\frac{\delta_t}{\bar{t}} \right)^2 \quad (7-7)$$

Upotrebljivost ove metode uvjetovana je postojanjem potpune krivulje trasea. To znači da se koncentracija trasea mora vratiti na vrijednost prije trasiranja. Jednačbe (7-4), (7-6) i (7-7) vrijede jedino u slučaju jednodimenzionalnog transporta.

Softver QTRACER2 ima mogućnost računanja longitudinalne disperzije i pomoću Chatwinove metode (Chatwin, 1971). Ta metoda se bazira na jednačbi:

$$\sqrt{t \ln \left(\frac{A_p}{C\sqrt{\bar{t}}} \right)} = \frac{x_s}{2\sqrt{D_L}} - \frac{\bar{v}t}{2\sqrt{D_L}} \quad (7-8)$$

Gdje je x_s = sinusoidalna udaljenost (m), D_L = koeficijent longitudinalne disperzije (m^2/s), \bar{v} = srednja brzina (m/s), t = vrijeme (s) i konstanta proporcionalnosti A_p ($kg s^{1/2} m^{-3}$).

$$A_p = \frac{M}{2A\sqrt{\pi D_L}} \quad (7-9)$$

Gdje je A = površina presjeka kanala (m^2), M = masa ubačenog trasera (kg).


U slučaju simetrične distribucije koncentracije (Davis et al., 2000) vrijedi izraz (7-10), iako je Day (1975) pokazao da su greške relativno zanemarive i u slučaju asimetrične distribucije

$$A_p = C_p \sqrt{t_p} \quad (7-10)$$

Gdje je C_p = maksimalna koncentracija (kg/m^3) i t_p = vrijeme maksimalne koncentracije (s)

Da bi mogli upotrijebiti Chatwinovu metodu rani dio krivulje koncentracije trasera mora se relativno dobro poklapati s ravnom linijom (Day, 1975).

Obje metode za izračun disperzije nisu u stanju kvantificirati disperziju uzrokovanu ne-mobilnim dijelovima toka tj. ne mogu objasniti izražene repove (polagano istjecanje nakon prolaska većine trasera) krivulja koncentracija trasera (Slika 7.3) (Maloszewski et al., 1998).



Slika 7.3. Usporedba advektivno – disperzivnog modela i modela neravnoteže s opažanim podacima na izvoru Dyers (Field & Pinsky, 2000)

7.1.3.2 Ravnotežni konvekcijsko – disperzijski model (CDE)

Obzirom na broj modeliranih parametara ravnotežni konvekcijsko – disperzijski model (*Equilibrium CDE* (eng. *Convection – Dispersion Equation*)) je najjednostavniji. Za njegovu primjenu nužno je modelirati samo konvekciju i disperziju. Mali broj parametara je zaslužan za jedinstvenost rješenja i radi toga bi to trebao biti standardni model za analizu kvantitativnih trasiranja. Izuzetak predstavljaju krivulje s izraženim repovima koje takvi modeli ne mogu adekvatno simulirati (Birk et al., 2005). U ovom radu će biti prikazani rezultati CDE modela izrađenim pomoću softvera Visual CXTFIT (Nützmann et al., 2005). Pretpostavljeno je da nema retardacije i trošenja prvog reda što je razumna pretpostavka s obzirom na konzervativnost korištenih trasera, te turbulentnog toka krškim kanalima (Käss, 1998; Field & Pinsky, 2000).

CDE model se zasniva na analitičkom rješenju jednadžbe transporta:

$$R \frac{\partial C}{\partial t} = D_L \frac{\partial^2 C}{\partial x^2} - v \frac{\partial C}{\partial x} - \mu C \quad (7-11)$$

Gdje je R = faktor retardacije (-), μ = koeficijent raspadanja prvog reda (s^{-1}), D_L = koeficijent longitudinalne disperzije (m^2/s), c = koncentracija (kg/m^3), t = vrijeme (s), x = udaljenost (m), v = efektivna brzina (m/s).

U ovom slučaju kalibriraju se tri parametra:

v – brzina (m/s)

D_L – koeficijent longitudinalne disperzije (m^2/s)

$R = 1 + 2 K_a/r$ – faktor retardacije, (K_a = koeficijent distribucije krute i tekuće faze u kanalima (m)), r = radijus kanala (m)

Analitičko rješenje koje nudi ovaj model ne može adekvatno uklopiti nejednoliko tečenje na izvorima koje je u kršu gotovo pravilo.

7.1.3.3 Jednopukotinski model disperzije (SFDM)


Jednopukotinski model disperzije (*SFDM (eng. Single Fissure Dispersion Model)*) predstavlja 1D model temeljen na jednadžbi:

$$C_f(t) = \frac{a \times M \sqrt{t_0}}{2\pi Q \sqrt{P_D}} \int_0^t \exp\left(-\frac{(t_0-u)^2}{4uP_D t_0} - \frac{a^2 u^2}{t-u}\right) \frac{du}{\sqrt{u(t-u)^3}} \quad (7-12)$$

$$a = \frac{n_p \sqrt{D_p}}{2b} \quad (7-13)$$

Gdje je C_f = koncentracija u pukotini (m^3/s), t = vrijeme (s), t_0 = srednje vrijeme prolaska trasera (s), u = varijabla integracije, M = masa trasera (kg), a = parametar koji opisuje proces difuzije u matriks ($s^{-1/2}$), n_p = poroznost matriksa (-), D_p = koeficijent molekularne difuzije matriksa (m^2/s), $2b$ = širina pukotine (m).

Zamišljen je prvenstveno za pukotinske vodonosnike s poroznim matriksom. Transport se odvija duž jedne ili više paralelnih pukotina (Slika 7.4). Pri tome dolazi do difuzije u matriks, ali je transport prekratak do traser dođe do susjednih pukotina (do nekoliko tjedana). Kasnijim otpuštanjem trasera iz matriksa može doći do produljenja krivulje trasera (Sudicky & Frind, 1982; Maloszewski & Zuber, 1985; Witthüser et al., 2003; Tsang & Tsang, 1987; Tsang & Neretnikes, 1998; Becker & Shapiro, 2003).



Slika 7.4. Konceptualni modeli tečenja kroz pukotinski vodonosnik. Lijevo koncept paralelnih pukotina među kojima je porozni matriks. Desno kanaliziranje toka u krškom vodonosniku (Leibundgut et al., 2009).

Za razliku od prije navedenih modela, u SFDM se kalibriraju 3 parametra (t_0 , P_e , a):

$$t_0 = x/v = V/Q \quad (7-14)$$

$$P_e = \frac{v \times x}{D} \quad (7-15)$$


$$a = \frac{n_p \sqrt{D_p}}{2b} \quad (7-16)$$

Gdje je t_0 = srednje vrijeme prolaska trasera (s), x = udaljenost (m), V = volumen mobilne vode u sustavu (m^3), Q = protok (m^3/s), v = efektivna brzina (m/s), P_e = pecletov broj (-), D = koeficijent disperzije u pukotini, n_p = poroznost matriksa (-), D_p = koeficijent molekularne difuzije matriksa (m^2/s), b = širina pukotine (m).

Prilikom rada na disertaciji, SFDM model je primijenjen korištenjem softvera TRACI95 (Maloszewski & Zuber, 1985).

7.1.3.4 Multi disperzijski model (MDM)

MDM (eng. *Multi-Dispersion Model*) predstavlja proširenje prethodnog modela (Maloszewski et al., 1992). SFDM model ne može objasniti produljene repove krivulja niti više pikova na jednoj krivulji. MDM taj problem rješava raščlanjivanjem krivulje trasera na dvije ili više zasebnih krivulja pri čemu svaka krivulja predstavlja jedan tok vode (Slika 7.5).



Slika 7.5. Krivulja trasera s više pikova i pripadajući konceptualni model tečenja (Leibundgut et al., 2009).

Nakon rastavljanja krivulje primjenjuju se jednadžbe prikazane u SFDM modelu.

Prilikom rada na disertaciji, MDM model je primijenjen korištenjem softvera TRACI95 (Maloszewski & Zuber, 1985).

7.1.3.5 Neravnotežni dvo – zonski model (2RNE)

2RNE (eng. *Two-region non-equilibrium*) predstavlja najsloženiji model jer omogućuje podešavanje najvećeg broja parametara od svih predstavljenih modela. Model se zasniva na postojanju dvije zone tečenja: mobilna i nemobilna zona između kojih postoji difuzija trasera (van Genuchten, 1981; Toride et al., 1999, Field & Pinsky 2000).

$$\theta_m \frac{\partial C_m}{\partial t} = \theta_m D_m \frac{\partial^2 C_m}{\partial x_s^2} - \theta_m v_m \frac{\partial C_m}{\partial x_s} - \alpha_t (C_m - C_{im}) - (\theta_m \mu_{l,m}) C_m \quad (7-17)$$

$$\left(\theta_{im} + \frac{2K_a}{r}\right) \frac{\partial C_m}{\partial t} = \alpha_t (C_m - C_{im}) - \left(\theta_{im} \mu_{l,m} + \frac{2K_a}{r} \mu_{ad,im}\right) C_{im} \quad (7-18)$$

Gdje se indeksi odnose na: m = mobilna zona, im = nemobilnu zonu, ad = adsorbirana faza, l = tekuća faza

θ = volumni udio vode (-), α_t = koeficijent prijenosa mase (s^{-1})

Jednadžbe se mogu pojednostaviti pisanjem u bezdimenzijskom obliku:

$$\beta R_f \frac{\partial C_1}{\partial T} = \frac{1}{P_e} \frac{\partial^2 C_1}{\partial Z^2} - \frac{\partial C_1}{\partial Z} - \omega (C_1 - C_2) - \mu_1 C_1 \quad (7-19)$$

$$(1 - \beta) R_f \frac{\partial C_2}{\partial T} = \omega (C_1 - C_2) - \mu_2 C_2 \quad (7-20)$$

Gdje se indeksi odnose na: 1 = faza 1(uravnotežena faza), 2 = faza 2 (neuravnotežena faza)

bezdimenzijski koeficijent udjela mobilne i nemobilne zone (maksimalni udio neravnoteže)

$$\beta = (\theta_m / (1 + 2 K_a / r)) \quad (7-21)$$

bezdimenzijski koeficijent prijenosa mase

$$\omega = \alpha_t L / \theta_m v_m \quad (7-22)$$

C = volumno uprosječene koncentracije otopine, μ = bezdimenzijski parametar raspadanja otopine, T = bezdimenzionalna vremenska varijabla, Z = bezdimenzionalna prostorna varijabla

Kod ovog modela kalibrira se šest parametra: v, D_L , β , R_f , P_e , ω .

Ovako veliki broj parametara ukazuje na višeznačnost rješenja. Prilikom određivanja parametra možemo si pomoći procjenom okvirnih vrijednosti nekih parametara.

$$\beta = \frac{v}{v_m} \approx \frac{\bar{v}}{v_p} \quad (7-23)$$

Gdje su v_p = brzina maksimalne koncentracije, \bar{v} = srednja brzina trasera


Jednadžba (7-23) pretpostavlja da nema retardacije ($R_f = 1$) trasera što je razumna pretpostavka za konzervativni traser ubačen u kanal velikog radijusa, malog hidrauličkog gradijenta i brzog turbulentnog toka. Dodatna pretpostavka je da nemobilne zone vrše utjecaj na mobilne zone u dovoljnoj mjeri da su razlike između v_m i v_p beznačajne (Field & Pinsky 2000).

U ovom radu u model su dodatno uključeni koeficijent udjela mobilne i nemobilne zone β ($0 < \beta < 1$; veći iznos ukazuje na veći udio mobilne zone) i koeficijent transfera mase ω koji opisuje izmjenu između dviju faza (veći iznos ukazuje na veći transfer mase). Obzirom da je prihvaćena pretpostavka da su oba trasera konzervativna, retardacija i koeficijenti raspadanja prvog reda u mobilnoj i nemobilnoj zoni nisu uzeti u obzir.

Složenost metode je omogućila analitičko rješenje samo za uvjete ujednačenog protoka. Usprkos tome, metoda je primjenjivana u kršu i u uvjetima vrlo varijabilnog toka (Göppert & Goldscheider, 2008).

7.1.4 Geometrija kanala

Veliki utjecaj na tečenje u podzemlju, a samim time i rezultate trasiranja, ima mreža preferiranih tokova (kanala). Negdje je dio tih kanala moguće izravno istražiti jer su dovoljno veliki za čovjeka i imaju prirodni ulaz s površine. Kada to nije moguće, osnovni tip kanala se može utvrditi kvantitativnim trasiranjem. Tako možemo razlikovati sedam osnovnih tipova kanala (Slika 7.6).



Slika 7.6. Sedam jednostavnih tipova mreža kanala koji opisuju kretanje trasera. Tip mreže znatno utječe na rezultate trasiranja. q - protok na ulazu, Q - protok na izlazu, m_i - masa trasera ubačenog na ulazu, T_T - masa utvrđenog trasera na izlazu (Field, 2002)

U slučaju kada imamo tip I, predviđanje rezultata trasiranja će vjerojatno biti približno točno. Kod tipa II i III točnost predviđanja će biti obrnuto proporcionalna količini boje koja je razrijeđena dodatnom količinom vode ili preusmjerena u nepoznate točke istjecanja.

Tipovi IVa i IVb dodatno kompliciraju interpretaciju zbog značajnog gubitka trasera, a protok istovremeno na izlazu može biti manji, veći ili jednak protoku na ulazu. Tip V je obično nepoželjan slučaj pri kojemu nećemo moći utvrditi traser na izlazu. To može dovesti do potencijalno pogrešnog zaključka da mjesto ubacivanja trasera nije

povezano, što ne mora biti slučaj. Moguće je da samo u trenutnim uvjetima nema tečenja prema opažanim lokacijama. U slučaju tip VI i VII postoji znatna količina uskladištene vode ili zasebni krški podsustav koji je spojen s glavnim sustavom. Ti podsustavi mogu biti mreže kanala bilo kojeg od tipova I, II, III, IV ili V. Mreže kanala tipa VI i VII su u principu samo specifični slučajevi tipa I. Tipovi VI i VII mogu biti vrlo značajni za transport zagađivala kroz krški sustav.

Pomoću krivulje koncentracije traseira možemo dobiti prihvatljive procjene volumena kanala, njihove površine presjeka (Smart, 1988b), površinu omočenog ruba i radijusa ako pretpostavimo formu cilindra (Field, 2002). Razlike stvarnog oblika kanala i cilindra će uzrokovati greške u procjeni. Za dobivanje prihvatljivih vrijednosti površine kanala nužno je definirati nepravilnosti (hrapavost) stijenki kanala (Field, 2002).

Volumen kanala se računa na osnovu srednjeg vremena prolaska traseira i protoka na izvoru (Atkinson et al., 1973).

$$V = \int_0^{\bar{t}} Q dt \quad (7-24)$$

U slučaju kada traser izlazi na više različitih izvora, potrebno je sumirati sve te volumene za dobivanje procjene ukupnog volumena kanala.

$$V_T = \sum_{i=1}^n V_i \quad (7-25)$$

Dobiveni volumen predstavlja grubu procjenu maksimalnog volumena sustava toka kojim teče traser. Najveći volumen u vodonosnicima zauzimaju mikro pore, ali one imaju malog utjecaja na tok pored krških kanala i pukotina. Radi toga je za pouzdanije procjene volumena vodonosnika preporučljivo usporediti različite metode (Field, 2002).

Nesigurnosti procjene parametara geometrije kanala se ne mogu kvantificirati (Field & Pinsky, 2000).

7.1.5 Traseri

Kao traser može poslužiti bilo koja tvar ili svojstvo vode pomoću koje se mogu dobiti informacije o tečenju vode i transportu materijala. U tu svrhu mogu poslužiti prirodni traseri koji se već nalaze u vodi bez utjecaja istraživača poput prirodnih tvari (ionski sastav, stabilni izotopi), antropogena zagađenja (sol za posipavanje cesta, tricij iz atomskih pokusa) i fizikalna svojstva vode (temperatura, elektrovodljivost) (Goldscheider & Drew 2007, Leibundgut et al. 2009). Osim njih postoje i umjetni traseri koje istraživač sam unese u sustav poput fluorescentnih boja, topivih soli, radioaktivnih trasera itd. U ovom poglavlju će se obrađivati samo umjetni traseri koji su korišteni u istraživanju. U poglavlju 5.2.3 je bilo nešto riječi o prirodnim traserima (elektrolitička vodljivost).

Da bi neka tvar mogla poslužiti kao traser treba zadovoljavati sljedeće uvjete (Käss 1998):

- Odsustvo u prirodnim vodama ili prisutna u vrlo niskim koncentracijama
- Moguće kvantitativno analiziranje s vrlo visokom razinom detektibilnosti
- Neškodljivo za čovjeka, biljke i životinje
- Dobra topivost u vodi i svojstva disperzije
- Stabilnost s obzirom na kemijske, biološke i fizikalne procese
- Nepodložnost interakciji s medijem kroz koji se kreće tj. nepodložnost sorpciji i ionskoj zamjeni
- Niski troškovi nabave, korištenja i analiziranja

Traser koji potpuno zadovoljava sve navedene uvjete naziva se idealni traser i ne postoji. Radi toga se u praksi koriste brojni traseri s obzirom na potrebe i uvjete u kojima se mogu koristiti. Svojstva odabranog trasera trebaju biti što bliže idealnima. To se najviše odnosi na konzervativna svojstva. S obzirom da nema idealnog trasera, prilikom svakog istraživanja treba razmotriti mane potencijalnog trasera s obzirom na uvjete u vodonosniku.

Umjetni traseri se mogu podijeliti na trasere topive u vodi (boje, soli, izotopi...) i čestice (spore, bakterije...) (Käss 1998). Posebno dobra svojstva su ustanovljena

kod fluorescentnih boja (Leibundgut et al. 2009). Radi toga su traseri korišteni za potrebe disertacije izabrani iz te skupine.

Fluorescentne boje imaju svojstvo fluorescencije. Fluorescencija je rezultat podražavanja molekule dovođenjem svjetlosne energije određene valne dužine. Određeni kemijski spoj fluorescencijom odašilje svjetlost veće valne dužine od one koju prima. Izvor pobude (ekscitacije) izbacuje elektron iz atoma s nižeg u više energetske stanje. Pri tome elektron odašilje svjetlosnu energiju (fluorescenciju), nakon čega se vraća u niže energetske stanje. Trajanje odašiljanja energije (emisije) traje samo dok traje ekscitacija. Intenzitet emisije je linearan intenzitetu ekscitacije i koncentracije fluorescentne tvari (traseira). Linearnost se gubi pri visokim koncentracijama radi pojave samozasjenjivanja fluorescentne tvari. U tom slučaju je potrebno otopinu razrijediti dok ne dođe u linearni raspon.

Intenzitet fluorescencije može ovisiti i o drugim fizikalnim, kemijskim ili biološkim faktorima. S obzirom da niti jedan traser nije apsolutno konzervativan, pri odabiru trasera treba uzeti u obzir uvjete u kojima će se nalaziti. Za potrebe izrade disertacije korištene su dvije fluorescentne boje. Obje korištene boje su neškodljive za floru, faunu i ljude.

7.1.5.1 Natrijev fluorescein (Uranin)

C.I. 45350, CAS 518-47-8, $C_{20}H_{10}Na_2O_5$, molekularna težina 376,28

Maksimum ekscitacije: 491 nm

322 nm (sekundarni maksimum)


Maksimum emisije: 512 nm

Topivost u vodi (20°C): >600 g/l

Uranin je u visokim koncentracijama u obliku praha smeđe-narančaste boje. U takvom obliku uranin ne pokazuje svojstvo fluorescencije. Tek kada se jako razrijedi

u vodi poprimi žuto-zelenu boju i pokazuje jako svojstvo fluorescencije. U vodi je vizualno vidljiv u koncentraciji većoj od 20 µg/l. Može se reći da uranin ima najveći intenzitet fluorescencije od svih fluorescentnih boja. Iako je neškodljiv za ljude, floru i faunu i u visokim koncentracijama, njegovu koncentraciju bi na mjestima opažanja trebalo pokušati držati ispod 20 µg/l radi psihološkog učinka na lokalno stanovništvo (Hubbard et al., 1982).


Uranin je najčešće upotrebljavan traser. Od svih trasera, njegova svojstva su najbliža svojstvima idealnog trasera. Kod primjene uranina posebnu pozornost treba dati pH. U neutralnom mediju uranin se pojavljuje kao neutralna molekula, u kiselom mediju je kation, a u alkalnom je jednovalentni ili dvovalentni anion. Fluorescenciju pokazuje samo u obliku aniona. U kationskom obliku uranin ima snažno svojstvo sorpcije što ga čini neprikladnim za upotrebu u kiselim sredinama. Intenzitet fluorescencije je jako ovisan o pH. Maksimalna fluorescencija se dostiže tek na pH većem od 8,5. Pri pH 7, mjereni intenzitet je samo 80% maksimalnog intenziteta (Slika 7.7).



Slika 7.7. Zavisnost intenziteta fluorescencije uranina i pH (Käss, 1998)

Promjena iz različitih oblika je reverzibilna i intenzitet fluorescencije se vraća na originalni intenzitet.

Uranin je fotosenzibilan tj. svjetlost ga uništava (Slika 7.8).



Slika 7.8. Raspadanje dva uzorka uranina koncentracije $10\mu\text{g/l}$. Gornja krivulja predstavlja uzorak u smeđoj (tamnijoj) staklenoj boci, a donja uzorak u prozirnoj boci. Boce su bile izložene danjem svijetlu s malo sunčanog vremena (Käss, 1998).

Može se naći radova u kojima se tvrdi da je uranin podložan sorpciji u glinovitim, laporovitim ili siltoznim naslagama (Käss, 1998 prema Prinz, 1923; Keil, 1959). Käss (1998) je testirao sorpciju na gline i došao do zaključka da uranin nije podložan sorpciji. Problematična su područja s niskim pH. U tom slučaju se svojstva uranina mijenjaju i može doći do pojave sorpcije. Takvi uvjeti se u prirodnim voda pojavljuju samo u močvarama, tresetištima, kiselim tlima i vodonosnicima u kristalinskim stijenkama (Leibundgut et al., 2009 prema Leibundgut, 1974; Behrens et al., 1982; Käss, 1998).

7.1.5.2 Natrijev naftionat

CAS 130-13-2, $\text{C}_{10}\text{H}_8\text{NNaO}_3\text{S}$, molekularna težina 245,23

Maksimum ekscitacije: 320 nm

237 nm, 218 nm (sekundarni maksimum)

Maksimum emisije: 420 nm

Topivost u vodi (21°C): 240 g/l

Naftionat dolazi u koncentraciji od 74% u obliku sivih kristalića. Intenzitet fluorescencije je znatno niži od uranina, a pozadinske koncentracije u prirodi redovito više. Iz tog razloga, prilikom izvođenja trasiranja treba ubaciti veću količinu naftionata nego što bismo ubacili uranina.

Naftionat ima i nekoliko prednosti nad uraninom. U vodi je vidljiv samo pri izrazito visokim koncentracijama (samo prilikom ubacivanja) što ga čini pogodnim za trasiranje vodoopskrbnih objekata. Stabilan je pri rasponu pH od 4 do 9 što je raspon većine voda u kojima se vrše trasiranja (Käss, 1998).

Kao i uranin, naftionat ima vrlo nisku sklonost sorpciji (Leibundgut et al., 2009).


Radi dovoljno različite valne dužine emisije uranina i naftionata, mogu se uspješno kombinirati u simultanim trasiranjima (Goldscheider & Drew, 2007 prema Wernli, 1986).

Naftionat je u Hrvatskoj prvi puta uspješno upotrijebljen tek 2009. godine na trasiranju Grobničkog polja iznad grada Rijeke (Kuhta et al., 2009).

7.1.6 Metode mjerenja koncentracije trasera

Glavni instrument za mjerenje koncentracije trasera bio je terenski fluorometar GGUN-FL30. Uređaj se postavlja u izvor i automatski mjeri koncentraciju od jednog do tri fluorescentna trasera (Slika 7.9). Dodatno mjeri i mutnoću pomoću koje se radi kompenzacija mjerenja koncentracije (Schnegg & Doerflinger, 1997; Schnegg, 2002; Schnegg, 2003). Interval mjerenja je u svim trasiranjima na kojima je korišten bio podešen na 15 minuta. Tako gusto i vremenski precizno mjerenje omogućava kvalitetu krivulje koncentracije kakvu bi bilo vrlo teško omogućiti ručnim uzorkovanjem. Osim toga nema mogućnosti zagađenja ili degradacije koncentracije u uzorcima. Osjetljivost instrumenta je nešto slabija naspram laboratorijskog određivanja koncentracije. Točan iznos ovisi o uvjetima na terenu, pa se ne može dati precizno. Generalno je najniža koncentracija trasera koju terenski fluorometar

može detektirati za red veličine veća od laboratorijskog. Usprkos tome, puno veća gustoća mjerenja uglavnom daje prednost podacima dobivenim terenskim fluorometrom. Sve krivulje koncentracije trasera koje su obrađene u radu dobivene su terenskim fluorometrima osim ako nije naglašeno suprotno.



Slika 7.9. Terenski fluorometri GGUN-FL-30 postavljeni na terenu; a – izvor Jaža; b – izvor Obrv

Na svim trasiranjima su na opažanim objektima (poglavlje 7.3) uzimani uzorci vode koji su analizirani u laboratoriju Hrvatskog geološkog instituta. Pri tome je korišten spektrofluorometar Perkin-Elmer LS55 (Slika 7.10). Pomoću tih uzoraka se kontrolirala eventualna pojava trasera na svim opažanim lokacijama. Na mjestima gdje su bili postavljeni terenski fluorometri, uzorci su bili samo u svrhu kontrole jer je učestalost uzimanja uzoraka bila premala za dobivanje zadovoljavajućih krivulja koncentracije.



Slika 7.10. Spektrofluorometar Perkin-Elmer LS55 Hrvatskog geološkog instituta


Na lokacijama koje se nisu redovito obilazile postavljeni su paketići aktivnog ugljena. Pomoću njih se dodatnom obradom u laboratoriju mogla ustanoviti prisutnost uranina.

7.2 Opis trasiranih objekata

Uzastopno su trasirani aktivni ponori P-1 i P-2 zapadno od brda Štula (Slika 4.1, str. 25). Oba ponora se nalaze na granici naslaga „Vivodinskog fliša“ i gornjokrednih vapnenačkih breča. U oba objekta poniru stalni vodotoci. Na ponorima je uspostavljeno opažanje razine vode, ali je bilo nemoguće izraditi protočnu krivulju za cijeli raspon protoka. Ponori se nalaze na krajevima slijepih dolina koje djelomično poplave tijekom velikih voda. Pored glavnih ponora, tada se javlja niz drugih povremenih ponora. U takvim uvjetima je bilo nemoguće izmjeriti protoke nužne za izradu kompletne protočne krivulje.

Ponor P-1 se nalazi na nadmorskoj visini od 380 metara, dok je P-2 na nadmorskoj visini od 350 metara. Najmanji izmjereni protok u razdoblju izrade disertacije je na ponoru P-1 bio 0,75 l/s, a najveći 198,3 l/s. U istom razdoblju, na ponoru P-2 je minimalno izmjereno 0,94 l/s, a maksimalno 361,2 l/s. Kod oba maksimalna izmjerena protoka je moguće da su podcijenjeni s obzirom na prethodno pojašnjenje.

Obzirom na rezultate prijašnjih trasiranja kojima se veza potvrdila isključivo na izvor Jaža, odabrana je dodatna lokacija za ubacivanje trase koja se nalazi u gornjotrijaskim dolomitima i za koju se pretpostavlja da je povezana s izvorom Obrv. Kao najpovoljnija lokacija izabrana je Jamina pod Piskom (Slika 4.1, str. 25). Radi se o jami istraženoj do dubine od 10 metara koja se nalazi u neposrednoj blizini sela Gornji Oštrc (Slika 7.11).



Slika 7.11. Nacrt Jamine pod Piskom. Crvenom isprekidanom linijom je na profilu približno označena razina lažnog dna u vrijeme ubacivanja trase.

Jama se nalazi u boku ponikve i djelomično je zapunjena tlom i otpadom. Na žalost, u vrijeme kada je ubačen traser, jama je praktički do polovice bila zapunjena otpadom. Ulaz u jamu se nalazi na nadmorskoj visini od 370 metara.

7.3 Opažacka mreža

Glavni predmet istraživanja su izvori Jaža i Obrv i njihovi pripadajući vodonosnici, te su na njima pri svakom trasiranju postavljeni terenski fluorometri i uzimani kontrolni uzorci vode. Iznimka je jedino prvo trasiranje koje je rađeno prvenstveno za potrebe izrade disertacije Vujnović (2010), kada su samo uzimani uzorci vode.

Iznimno je terenski fluorometar postavljen i na izvor Studena u vrijeme trasiranja Jamine pod Piskom. Uz fluorometar su također uzimani kontrolni uzorci vode i postavljeni paketići s aktivnim ugljenom.

Ostale lokacije su opažane isključivo paketićima s aktivnim ugljenom i povremenim uzorkovanjem vode. Opažani su izvori Zdenac i Vrulja podno brda Štula, te izvor na desnoj strani potoka Jaševnica, otprilike 300 metara nizvodno od izvora Jaža. Osim okolnih izvora, opažani su i potoci Kamenica kod Vivodine, Kupčina kod Jurkovog Sela i povremeni potok kod Žamarije (samo kod trasiranja Jamine pod Piskom).

7.4 Rezultati trasiranja

Sva trasiranja ponora P-1 i P-2 su dala rezultat isključivo na izvor Jažu. Trasiranje izvedeno u Jamini pod Piskom je rezultiralo pojavom trasera isključivo na izvoru Obrv. Iako se smjerovi toka nisu mijenjali ovisno o hidrološkim uvjetima, uvjeti i parametri tečenja su izrazito varirali. U daljnjem tekstu su rezultati prikazani za svako pojedinačno trasiranje.


7.4.1 Trasiranje ponora P-1 izvedeno 11. svibnja 2009. godine

Trasiranje je izvršeno ubacivanjem 500 grama uranina u ponor P-1, 11. svibnja 2009. godine u 13 sati. Simultano je izvedeno i trasiranje ponora P-2 s 3358 grama naftionata, ali radi gubitka dva ključna uzorka, krivulja koncentracije tog trasera s izvora Jaža nije zadovoljavajuća za potrebe ovog istraživanja te neće biti prikazana i obrađivana.

U to vrijeme još nije bio uspostavljeno kontinuirano opažanje dinamike izvora Jaže i Obrva, pa je izvršeno mjerenje protoka hidrometrijskim krilom u tri navrata tijekom trasiranja. Ustanovljeno je da su izvori bili u uvjetima srednjih voda i to u recesijskom dijelu. U razdoblju od 11. svibnja do 23. svibnja 2009. godine protok na Jaži je pao s 49 l/s na 13 l/s (Slika 7.12). U periodu neposredno prije i tijekom trasiranja nije bilo oborina na tom području.

7.4.1.1 Osnovni parametri

Traser se pojavio isključivo na izvoru Jaža. Krivulju trasera karakterizira izraziti pik, male asimetrije (Slika 7.12). Maksimalna koncentracija je bila 103,93 $\mu\text{g/l}$ što je višestruko više od granice vizualne detekcije uranina. Nakon pika je uslijedio rep krivulje relativno niske koncentracije.



Slika 7.12. Krivulja koncentracije trasera (uranina) i protoka na izvoru Jaža.

U Tablica 7.1 prikazani su osnovni rezultati trasiranja. Prividne brzine prikazane u tablici izračunate su pomoću korigirane udaljenosti. Ukoliko bi računali s pravocrtnom udaljenošću, prividna brzina prve pojave trasera bi bila 0,88 cm/s.

Tablica 7.1. Osnovni parametri trasiranja ponora P-1 izvedenog u svibnju 2009. godine. Prividne brzine su izračunate pomoću korigirane udaljenosti.

Podzemna veza	Pravocrtna udaljenost (m)	Korigirana udaljenost (m)	Visinska razlika (m)	Vrijeme do prve pojave (sati)	Prividna brzina prve pojave (cm/s)
P-1 - Jaža	1765	2647	110	56	1,31
Podzemna veza	Maksimalna koncentracija (µg/l)	Vrijeme do pojave maks. konc. (sati)	Prividna brzina maks. konc. (cm/s)	Vrijeme zadnje pojave (dani)	Pronos (%)
P-1 - Jaža	103,93	84	0,88	12	87,18

Pronos je ispao visokih 87,18 %. Traser je na izvoru istjecao ukupno 9 dana i 16 sati.

7.4.1.2 Modelirani parametri

Tablica 7.2 prikazuje rezultate svih analitičkih modela za procjenu parametara toka i transporta, izvedenih na trasiranju izvedenom u svibnju 2009. godine. Rezultati pojedinačnih modela su detaljnije opisani u nastavku teksta.


Tablica 7.2. Rezultati modela za parametre toka i transporta trasiranja izvedenog u svibnju 2009. godine

MODEL		SVOJSTVO	SIMBOL	JEDINICA	P-1 - JAŽA
metoda momenata s Chatwinovom metodom		srednje vrijeme prolaska trasera	t_0	h	93,88
		efektivna brzina	v	cm/s	0,78
		long. Disperzija	D_L	m^2/h	675,54
		disperzivnost	α	m	23,95
		pecletov broj	Pe	-	110,52
CDE		srednje vrijeme prolaska trasera	t_0	h	86,49
		efektivna brzina	v	cm/s	0,85
		long. Disperzija	D_L	m^2/h	901,90
		disperzivnost	α	m	29,46
		pecletov broj	Pe	-	89,85
SFDM		srednje vrijeme prolaska trasera	t_0	h	82,95
		efektivna brzina	v	cm/s	0,89
		long. Disperzija	D_L	m^2/h	765,54
		disperzivnost	α	m	23,99
		pecletov broj	Pe	-	110,34
		difuzija u matriks	a	$h^{-0.5}$	0,00423
MDM - SFDM	PIK 1	srednje vrijeme prolaska trasera	t_0	h	82,95
		efektivna brzina	v	cm/s	0,89
		long. Disperzija	D_L	m^2/h	768,68
		disperzivnost	α	m	24,09
		pecletov broj	Pe	-	109,89
		difuzija u matriks	a	$h^{-0.5}$	0,00348
	PIK 2	srednje vrijeme prolaska trasera	t_0	h	132,30
		efektivna brzina	v	cm/s	0,56
		long. Disperzija	D_L	m^2/h	1290,40
		disperzivnost	α	m	64,50
		pecletov broj	Pe	-	41,04
		difuzija u matriks	a	$h^{-0.5}$	0,00478
2RNE		srednje vrijeme prolaska trasera	t_0	h	93,88
		efektivna brzina	v	cm/s	0,78
		long. Disperzija	D_L	m^2/h	562,90
		disperzivnost	α	m	19,96
		pecletov broj	Pe	-	132,63
		koeficijent udjela mobilne i nemobilne zone	β	-	0,90
		koeficijent prijenosa mase	ω	-	0,31

7.4.1.2.1 Metoda momenata s Chatwinovom metodom

Srednje vrijeme prolaska trasera je metodom momenata određeno na 93,88 sati. Uzimajući u obzir korigiranu udaljenost ponora P-1 i izvora Jaža, dobiva se srednja brzina od 0,78 cm/s.

Za izračun disperzije korištena je Chatwinova metoda (Slika 7.13). Disperzija određena na taj način je procijenjena na 675,54 m²/h ili izraženo kroz disperzivnost 23,95 m. Pecletov broj prema tome ispada 110,52.




Slika 7.13. Izračun Chatwinovog parametra za trasiranje uraninom izvedeno u svibnju 2009. godine

Pomoću softvera QTRACER2 je određen i volumen kanala koji sudjeluju u toku na 14 260 m³. Pretpostavljajući cilindričnost kanala, površina njegovog presjeka iznosi 5,39 m² što daje polumjer od 1,31 m.

7.4.1.2.2 Equilibrium CDE – ravnotežni konvekcijsko-disperzijski model

CDE modelom se modelira samo srednja brzina prolaska trase i disperzija. Parametri modelirane krivulje su dali srednju brzinu od 0,85 cm/s i longitudinalna disperzija 901,9 m²/h (Slika 7.14).




Slika 7.14. Rezultati CDE modela za trasiranje uraninom izvedeno u svibnju 2009. godine

Iz dobivenih parametara se može izračunati disperzivnost koja iznosi 29,46 m, te Pecletov broj 89,85.

7.4.1.2.3 SFDM – jednopukotinski model disperzije

Jednopukotinskim modelom su modelirani srednja brzina, pecletov broj i parametar a koji opisuje difuziju u matriks. Srednja brzina modelirane krivulje iznosi 0,89 cm/s, a pecletov broj 110,34. Parametar a je određen na 0,00423 h^{-0,5} (Slika 7.15).




Slika 7.15. Rezultati SFDM modela za trasiranje uraninom izvedeno u svibnju 2009. godine

Pomoću modeliranih parametara se može izračunati longitudinalna disperzija od 765,83 m²/h i disperzivnost od 24,0 m.

7.4.1.2.4 MDM – multi disperzijski model

Multidisperzijski model je proveden kombinirajući dvije krivulje koncentracije trasera dobivene pomoću SFDM modela (Slika 7.16). Prva krivulja je vrlo slična SFDM modelu, pa time i dobiveni parametri. Srednja brzina je 0,89 cm/s, pecletov broj 108,99, dok je parametar a određen na 0,00004 h^{-0,5}. Dodatno su za prvu krivulju izračunati longitudinalna disperzija 775,43 m²/h i disperzivnost od 24,29 m.




Slika 7.16. Rezultati MDM modela za trasiranje uraninom izvedeno u svibnju 2009. godine

Druga modelirana krivulja u najvećem dijelu simulira rep opažane krivulje koncentracije trasera. Njezina srednja brzina iznosi 0,56 cm/s, pecletov broj je 41,61, te je parametar a 0,00004.

Izračunata je longitudinalna disperzija od 1276,68 m²/h i disperzivnost 63,63 m.

7.4.1.2.5 2RNE – neravnotežni dvo-zonski model

Ovim modelom su modelirana četiri parametra kojima se pokušala simulirati opažana krivulja koncentracije trasera (Slika 7.17). Srednja brzina je procijenjena na 0,78 cm/s, a longitudinalna disperzija na 562,9 m²/h. Koeficijent udjela mobilne i nemobilne zone β procijenjen je na 0,9, dok je koeficijent prijenosa mase ω procijenjen na 0,31.




Slika 7.17. Rezultati 2RNE modela za trasiranje uraninom izvedeno u svibnju 2009. godine

Iz modeliranih parametara su dodatno izračunata disperzivnost s iznosom 19,96 m i pecletov broj s iznosom 132,63.

7.4.2 Trasiranje ponora P-1 izvedeno 21. srpnja 2011. godine

Obzirom na poznate rezultate prijašnjeg trasiranja, ovaj puta je ubačeno manje uranina da se izbjegne vidljiva koncentracija na izvoru. U ponor P-1 je 21. srpnja 2011. godine, u 13:15 sati ubačeno 100 grama uranina. Istovremeno je trasiran i ponor P-2 s 3 kilograma naftionata.


U vrijeme ubacivanja uranina u ponor P-1, na izvoru Jaža je bio režim niskih voda. Na izvoru je istjecalo nešto više od 5 l/s vode. Razdoblje prije trasiranja je bilo s malo oborina, a taj trend je prekinut tri dana nakon ubacivanja uranina. Prva jača kiša od 20,6 mm je pala 24. srpnja i uzrokovala je manji porast protoka na izvoru Jaža. Tek je 28. srpnja palo 38,6 mm kiše koja je jako podigla protoke na ponorima i izvorima (Slika 7.18).



Slika 7.18. Protok vode na ponoru P-1 u razdoblju od 1. srpnja 2011. godine, pa do kraja istjecanja trasera i količina oborina na najbližem kišomjeru u Radinoj Vasi

7.4.2.1 Osnovni parametri

Uranin se pojavio isključivo na izvoru Jaža. Glavni pik uranina se izrazito dobro preklapio s nadolaskom vodnog vala uzrokovano kišom palom 28. srpnja. Pik je izrazito uzak, a prolaskom glavnog vodnog vala je prešao u rep relativno visoke koncentracije i dugog trajanja (Slika 7.19).



Slika 7.19. Krivulja koncentracije trasera (uranina) i protoka na izvoru Jaža.

Maksimalna koncentracija je na izvoru Jaža zabilježena nakon više od sedam dana nakon ubacivanja trasera u ponor i iznosila je 14,68 µg/l (Tablica 7.3). Ukupno trajanje istjecanja trasera je bilo 9 dana i 4,5 sati. Obzirom na izmjereni protok i koncentracije uranina, pronos je izračunat u iznosu od 104,5 %, što je više od teoretski maksimalnih mogućih 100 % (objašnjenje u poglavlju 8.1.2, str. 170).

Tablica 7.3. Osnovni parametri trasiranja ponora P-1 izvedenog u srpnju 2011. godine. Prividne brzine su izračunate pomoću korigirane udaljenosti.

Podzemna veza	Pravocrtna udaljenost (m)	Korigirana udaljenost (m)	Visinska razlika (m)	Vrijeme do prve pojave (sati)	Prividna brzina prve pojave (cm/s)
P-1 - Jaža	1765	2647	110	155,75	0,47
Podzemna veza	Maksimalna koncentracija (µg/l)	Vrijeme do pojave maks. konc. (sati)	Prividna brzina maks. konc. (cm/s)	Vrijeme zadnje pojave (dani)	Pronos (%)
P-1 - Jaža	14,68	171,5	0,43	15,69	104,5

U slučaju da prividnu brzinu prvog nailaska izračunamo pomoću pravocrtna udaljenosti, a ne korigirane udaljenosti, njen iznos bi iznosio 0,31 cm/s.

7.4.2.2 Modelirani parametri

Tablica 7.4 prikazuje rezultate svih modela za trasiranje.

Tablica 7.4. Rezultati modela za parametre toka i transporta trasiranja izvedenog u srpnju 2011. godine


MODEL		SVOJSTVO	SIMBOL	JEDINICA	P-1 - JAŽA
metoda momenata s Chatwinovom metodom		srednje vrijeme prolaska trasera	t_0	h	252,50
		efektivna brzina	v	cm/s	0,41
		long. Disperzija	D_L	m^2/h	9,40
		disperzivnost	α	m	0,63
		pecletov broj	Pe	-	4179,20
CDE*		srednje vrijeme prolaska trasera	t_0	h	173,04
		efektivna brzina	v	cm/s	0,43
		long. Disperzija	D_L	m^2/h	8,88
		disperzivnost	α	m	0,58
		pecletov broj	Pe	-	4561,06
SFDM		srednje vrijeme prolaska trasera	t_0	h	170,72
		efektivna brzina	v	cm/s	0,43
		long. Disperzija	D_L	m^2/h	5,15
		disperzivnost	α	m	0,33
		pecletov broj	Pe	-	7966,06
		difuzija u matriks	a	$h^{-0.5}$	0,00036
MDM - SFDM	PIK 1	srednje vrijeme prolaska trasera	t_0	h	170,72
		efektivna brzina	v	cm/s	0,43
		long. Disperzija	D_L	m^2/h	5,15
		disperzivnost	α	m	0,33
		pecletov broj	Pe	-	7966,06
		difuzija u matriks	a	$h^{-0.5}$	0,00036
	PIK 2	srednje vrijeme prolaska trasera	t_0	h	202,83
		efektivna brzina	v	cm/s	0,36
		long. Disperzija	D_L	m^2/h	243,41
		disperzivnost	α	m	18,65
		pecletov broj	Pe	-	141,98
		difuzija u matriks	a	$h^{-0.5}$	0,00247
2RNE*		srednje vrijeme prolaska trasera	t_0	h	217,36
		efektivna brzina	v	cm/s	0,34
		long. Disperzija	D_L	m^2/h	2,76
		disperzivnost	α	m	0,23
		pecletov broj	Pe	-	11700,49
		koeficijent udjela mobilne i nemobilne zone	β	-	0,79
		koeficijent prijenosa mase	ω	-	1,49

* - modelirana ulazna masa trasera

7.4.2.2.1 Metoda momenata s Chatwinovom metodom

Srednje vrijeme prolaska trasera je metodom momenata određeno na 252,5 sati što daje srednju brzinu prolaska trasera od 0,41 cm/s.

Chatwinovom metodom je disperzija procijenjena na 9,4 m²/h ili izraženo kroz disperzivnost 0,63 m. Pecletov broj prema tome ispada 4179,2 (Slika 7.20).




Slika 7.20. Izračun Chatwinovog parametra za trasiranje uraninom izvedeno u srpnju 2011. godine

Volumen kanala koji sudjeluju u toku procijenjen je na 17 084 m³. Pretpostavljajući cilindričnost kanala, površina njegovog presjeka iznosi 6,45 m² što daje polumjer od 1,43 m.

7.4.2.2.2 Equilibrium CDE – ravnotežni konvekcijsko-disperzijski model

U slučaju ovog trasiranja nije bilo moguće doći do zadovoljavajućeg preklapanja modelirane i opažane krivulje koncentracije trasera. Prihvatljivo rješenje je dobiveno tek modeliranjem i ulazne mase ubačenog trasera. U skladu s time, ulazna masa uranina je određena na samo 10,8 grama, naspram 100 grama uranina koji je ubačen.

Srednja brzina prolaska trasera je određena na 0,43 cm/s, a disperzija na 8,88 m²/h




Slika 7.21. Rezultati CDE modela za trasiranje uraninom izvedeno u srpnju 2011. godine

Iz dobivenih parametara se može izračunati disperzivnost koja iznosi 0,58 m, te Pecletov broj 4561,06.

7.4.2.2.3 SFDM i MDM– jednopukotinski model disperzije i multidisperzijski model

Obzirom da su rezultati SFDM modela identični s rezultatima prve krivulje MDM modela, njihovi rezultati će biti prikazani zajedno. Pri tome rezultati 1. krivulje MDM modela predstavljaju ujedno i rezultate SFDM modela (Slika 7.22).




Slika 7.22. Rezultati SFDM i MDM modela za trasiranje uraninom izvedeno u srpnju 2011. godine

Srednja brzina prve krivulje je procijenjena na 0,43 cm/s, a Pecletov broj na 7 966,06. Difuzija u matriks je procijenjena na $0,00036 \text{ h}^{-0,5}$. Iz toga možemo zaključiti da je iznos longitudinalne disperzije $5,15 \text{ m}^2/\text{h}$ i disperzivnosti 0,33 m.

Za simuliranje cijele opažane krivulje koncentracije trasera bilo je potrebno modelirati još jednu dodatnu krivulju. Njena srednja brzina iznosi 0,36 cm/s, a Pecletov broj je 141,98. Difuzija u matriks iznosi $0,00247 \text{ h}^{-0,5}$. Također možemo izračunati longitudinalnu disperziju i disperzivnost, pa oni iznose redom $243,41 \text{ m}^2/\text{h}$ i 18,65 m.

7.4.2.2.4 2RNE – Neravnotežni dvo-zonski model

Prilikom modeliranja u 2RNE modelu je došlo do istih problema kao i u CDE modelu. Za zadovoljavajuće preklapanje krivulja opažane i modelirane koncentracije je bilo neophodno modelirati i ulaznu masu uranina (Slika 7.23). U ovom slučaju je ulazna masa određena na 30,76 grama naspram ubačenih 100 grama uranina.



Slika 7.23. Rezultati 2RNE modela za trasiranje uraninom izvedeno u srpnju 2011. godine


Srednja efektivna brzina trasera je procijenjena na 0,34 m/s, dok je longitudinalna disperzija procijenjena na 2,76 m²/h. Iz toga možemo izračunati disperzivnost od 0,23 m i Pecletov broj 11 700,49.

Iznos koeficijenta udjela mobilne i nemobilne zone je procijenjen na 0,79, dok je koeficijent prijenosa mase 1,49.

7.4.3 Trasiranje ponora P-2 izvedeno 21. srpnja 2011. godine

Ponor P-2 je trasiran s 3000 grama naftionata 21. srpnja 2011. godine u 13:30 sati, simultano s trasiranjem ponora P-1 koji je trasiran s uraninom.


Uvjeti na izvoru Jaža su bili identični onima opisanim u poglavlju 7.4.2 obzirom da su oba trasiranja izvršena simultano. Slika 7.24 prikazuje hidrološke uvjete na ponoru P-2 u vrijeme trasiranja. Hidrološki uvjeti na ponoru su prikazani pomoću razine vode. 26. srpnja logeri za mjerenje razine vode su premješteni na drugu lokaciju zbog promjene tečenja potoka koji ponire u ponor P-2. Radi toga je vidljiv prekid na razini vode.



Slika 7.24. Protok vode na ponoru P-2 u razdoblju od 1. srpnja 2011. godine, pa do kraja istjecanja trasera i količina oborina na najbližem kišomjeru u Radinoj Vasi. Podaci o protoku su nedostupni za razdoblje prije 27.7.2011. godine radi premještanja logera.

7.4.3.1 Osnovni parametri

Uranin se pojavio isključivo na izvoru Jaža. Dolazak naftionata se poklopio s dolaskom vodnog vala na izvor Jažu. Za razliku od uranina, koji je najvećim dijelom istekao tijekom trajanja vodnog vala, glavnina naftionata je došla neposredno nakon. Krivulja se sastoji od izrazitog pika koji je puno širi od pika uranina. Rep je također puno dužeg trajanja nego u slučaju uranina (Slika 7.25).



Slika 7.25. Krivulja koncentracije trasera (naftionata) i protoka na izvoru Jaža.

Naftionat je na izvor Jažu stigao pet sati nakon dolaska uranina, dok je maksimalna koncentracija došla dva dana i osamnaest sati nakon maksimalne koncentracije uranina. Naftionat je ukupno istjecao skoro 50 dana i ostvario pronos od samo 55 % (Tablica 7.5).

Tablica 7.5. Osnovni parametri trasiranja ponora P-2 izvedenog u srpnju 2011. godine. Prividne brzine su izračunate pomoću korigirane udaljenosti.

Podzemna veza	Pravocrtna udaljenost (m)	Korigirana udaljenost (m)	Visinska razlika (m)	Vrijeme do prve pojave (sati)	Prividna brzina prve pojave (cm/s)
P-2 - Jaža	2110	3165	140	161	0,55
Podzemna veza	Maksimalna koncentracija (µg/l)	Vrijeme do pojave maks. konc. (sati)	Prividna brzina maks. konc. (cm/s)	Vrijeme zadnje pojave (dani)	Pronos (%)
P-2 - Jaža	175,61	237,5	0,37	56,68	55,05

U slučaju da prividnu brzinu prvog nailaska izračunamo pomoću pravocrtna udaljenosti, a ne korigirane udaljenosti, njen iznos bi iznosio 0,36 cm/s.

7.4.3.2 Modelirani parametri

Tablica 7.6 daje sažeti prikaz rezultata svih modela provedenih na trasiranju ponora P-2 naftionatom u srpnju 2011. godine.


Tablica 7.6. Rezultati modela za parametre toka i transporta trasiranja izvedenog u srpnju 2011. godine

MODEL		SVOJSTVO	SIMBOL	JEDINICA	P-1 - JAŽA
metoda momenata s Chatwinovom metodom		srednje vrijeme prolaska trasera	t_0	h	252,74
		efektivna brzina	v	cm/s	0,35
		long. Disperzija	D_L	m^2/h	571,07
		disperzivnost	α	m	45,60
		pecletov broj	Pe	-	69,40
CDE		srednje vrijeme prolaska trasera	t_0	h	273,08
		efektivna brzina	v	cm/s	0,32
		long. Disperzija	D_L	m^2/h	1174,00
		disperzivnost	α	m	101,29
		pecletov broj	Pe	-	31,25
SFDM		srednje vrijeme prolaska trasera	t_0	h	254,18
		efektivna brzina	v	cm/s	0,35
		long. Disperzija	D_L	m^2/h	1021,70
		disperzivnost	α	m	82,05
		pecletov broj	Pe	-	38,57
		difuzija u matriks	a	$h^{-0.5}$	0,00171
MDM - SFDM	PIK 1	srednje vrijeme prolaska trasera	t_0	h	254,18
		efektivna brzina	v	cm/s	0,35
		long. Disperzija	D_L	m^2/h	1021,70
		disperzivnost	α	m	82,05
		pecletov broj	Pe	-	38,57
		difuzija u matriks	a	$h^{-0.5}$	0,00171
	PIK 2	srednje vrijeme prolaska trasera	t_0	h	454,07
		efektivna brzina	v	cm/s	0,19
		long. Disperzija	D_L	m^2/h	57,99
		disperzivnost	α	m	8,32
		pecletov broj	Pe	-	380,43
		difuzija u matriks	a	$h^{-0.5}$	0,01343
2RNE		srednje vrijeme prolaska trasera	t_0	h	297,18
		efektivna brzina	v	cm/s	0,30
		long. Disperzija	D_L	m^2/h	839,50
		disperzivnost	α	m	78,83
		pecletov broj	Pe	-	40,15
		koeficijent udjela mobilne i nemobilne zone	β	-	0,89
		koeficijent prijenosa mase	ω	-	0,21

7.4.3.2.1 Metoda momenata s Chatwinovom metodom

Metodom momenata je srednje vrijeme prolaska trasera određeno na 252,74 sata. Obzirom na korigiranu udaljenost srednja brzina je 0,35 cm/s.

Chatwinovom metodom je longitudinalna disperzija određena na 571,07 m²/h (Slika 7.26). Iz toga se mogu izračunati disperzivnost od 45,6 m i Pecletov broj od 69,4.




Slika 7.26. Izračun Chatwinovog parametra za trasiranje naftionatom izvedeno u srpnju 2011. godine

Procijenjeni volumen kanala koji sudjeluju u toku iznosi 24 507 m³. Ako pretpostavimo cilindričan oblik kanala, njegov polumjer bi iznosio 1,57 m, dok bi mu površina presjeka iznosila 7,74 m².

7.4.3.2.2 Equilibrium CDE – ravnotežni konvekcijsko-disperzijski model

Srednje vrijeme prolaska naftionata je CDE modelom određeno na 273,08 sati (Slika 7.27). U skladu s time, srednja brzina je 0,32 cm/s.




Slika 7.27. Rezultati CDE modela za trasiranje naftionatom izvedeno u srpnju 2011. godine

Longitudinalna disperzija je procijenjena na $1174 \text{ m}^2/\text{h}$. na temelju toga se može zaključiti da je iznos disperzivnosti 101,29 m, a Pecletov broj 31,25.

7.4.3.2.3 SFDM i MDM – jednopukotinski model disperzije i multidisperzijski model

Kao i u slučaju simultanog trasiranja s uraninom, rezultati SFDM modela i prve krivulje MDM modela su identični. Radi toga će njihovi rezultati biti prikazani skupno unutar ovog poglavlja. Rezultati prve krivulje MDM modela su ujedno i rezultati SFDM modela (Slika 7.28).




Slika 7.28. Rezultati SFDM i MDM modela za trasiranje naftionatom izvedeno u srpnju 2011. godine

Srednje vrijeme prve krivulje je određeno na 254,18 sati, a srednja brzina na 0,35 cm/s. Longitudinalna disperzija iste krivulje je 1021,7 m²/h što rezultira disperzivnošću od 82,05 m i Pecletovim brojem 38,57. Difuzija u matriks je procijenjena na 0,00171 h^{-0,5}.

Za simuliranje cijele opažane krivulje je modelirana dodatna krivulja koja simulira njezin rep. Srednje vrijeme te krivulje je 454,07 sati tj. srednja brzina je 0,19 cm/s. Longitudinalna disperzija je 57,99 m²/h što rezultira disperzivnošću od 8,32 m i Pecletovim brojem 380,43. Difuzija u matriks iznosi 0,01343 h^{-0,5}.

7.4.3.2.4 2RNE – neravnotežni dvo-zonski model

Srednje vrijeme dobiveno 2RNE modelom iznosi 297,18 sati što računato s korigiranom udaljenošću rezultira srednjom brzinom od 0,3 cm/s (Slika 7.29).



Slika 7.29. Rezultati 2RNE modela za trasiranje naftionatom izvedeno u srpnju 2011. godine

Longitudinalna disperzija iznosi $839,5 \text{ m}^2/\text{h}$. Pomoću nje možemo izračunati disperzivnost u iznosu od $78,83 \text{ m}$ i Pecletov broj $40,15$.


Specifični parametri 2RNE modela su koeficijent udjela mobilne i nemobilne zone β u iznosu od $0,89$ i koeficijent prijenosa mase ω u iznosu od $0,21$.

7.4.4 Trasiranje ponora P-1 izvedeno 23. veljače 2012. godine

Trasiranje ponora P-1 je izvršeno 23. veljače 2012. godine u 13 sati sa 100 grama uranina. Simultano je izvedeno trasiranje ponora P-2 (opisano u poglavlju 7.4.5).

U razdoblju prije trasiranja na izvorima Jaža i Obrv je bio režim niskih voda koji je trajao od srpnja 2011. godine. U tom periodu je bilo oborina, ali u premalim količinama za dugotrajno podizanje razina podzemne vode. Tek je u razdoblju od 16. do 20. veljače 2012. godine pala nešto značajnija količina oborina u obliku snijega koji je ubrzo otopljen. Oba trasera su ubačena u ponore 23. veljače u 13 sati. U vrijeme bacanja trasera, manje količine snijega su ostale samo u izoliranim


područjima u sjeni. Razina vode na ponorima je porasla uslijed topljenja snijega. 100 grama uranina je ubačeno u ponor P-1 u sredini vodnog vala. Do kraja trasiranja nije bilo značajnijih oborina (Slika 7.30). Obzirom da su oborine u periodu trasiranja bile većinom u formi snijega, njihove količine nisu adekvatno zabilježene na kišomjeru.



Slika 7.30. Protok vode na ponoru P-1 u razdoblju od 1. veljače 2012. godine, pa do kraja istjecanja trasera i količina oborina na najbližem kišomjeru u Radinoj Vasi

7.4.4.1 Osnovni parametri

Kao i kod ostalih trasiranja ponora P-1, dolazak trasera je zabilježen isključivo na izvoru Jaža. Krivulja koncentracije uranina se odlikuje malom asimetrijom izrazito izraženog pika i vrlo izduženim repom niske koncentracije (Slika 7.31). Dolazak glavnog dijela ubačenog uranina je došao za vrijeme trajanja pojačanog protoka na izvoru Jaža.



Slika 7.31. Krivulja koncentracije trasera (uranina) i protoka na izvoru Jaža

Do dolaska maksimalne koncentracije uranina od 19,63 µg/l na izvor Jaža je prošlo malo više od dva dana nakon ubacivanja u ponor P-1 (Tablica 7.7). Ukupno trajanje istjecanja uranina je bilo skoro 22 dana, od čega piku krivulje pripada tek dvadesetak sati. Pronos trasera je bio vrlo visokih 97,25 %.

Tablica 7.7. Osnovni parametri trasiranja ponora P-1 izvedenog u veljači 2012. godine. Prividne brzine su izračunate pomoću korigirane udaljenosti.

Podzemna veza	Pravocrtna udaljenost (m)	Korigirana udaljenost (m)	Visinska razlika (m)	Vrijeme do prve pojave (sati)	Prividna brzina prve pojave (cm/s)
P-1 - Jaža	1765	2647	110	38,55	1,91
Podzemna veza	Maksimalna koncentracija (µg/l)	Vrijeme do pojave maks. konc. (sati)	Prividna brzina maks. konc. (cm/s)	Vrijeme zadnje pojave (dani)	Pronos (%)
P-1 - Jaža	19,63	49,5	1,49	23,53	97,25

Prividna brzina prvog nailaska, izračunata preko pravocrtna udaljenosti ponora P-1 i izvora Jaža, iznosi 1,27 cm/s.

7.4.4.2 Modelirani parametri

Tablica 7.8 prikazuje rezultate svih modela za trasiranje uraninom.


Tablica 7.8. Rezultati modela za parametre toka i transporta trasiranja izvedenog u veljači 2012. godine

MODEL		SVOJSTVO	SIMBOL	JEDINICA	P-1 - JAŽA
metoda momenata s Chatwinovom metodom		srednje vrijeme prolaska trasera	t_0	h	68,78
		efektivna brzina	v	cm/s	1,07
		long. Disperzija	D_L	m^2/h	560,77
		disperzivnost	α	m	14,57
		pecletov broj	Pe	-	181,72
CDE		srednje vrijeme prolaska trasera	t_0	h	50,01
		efektivna brzina	v	cm/s	1,47
		long. Disperzija	D_L	m^2/h	458,10
		disperzivnost	α	m	8,65
		pecletov broj	Pe	-	305,96
SFDM		srednje vrijeme prolaska trasera	t_0	h	48,76
		efektivna brzina	v	cm/s	1,51
		long. Disperzija	D_L	m^2/h	371,81
		disperzivnost	α	m	6,85
		pecletov broj	Pe	-	386,63
		difuzija u matriks	a	$h^{-0.5}$	0,00220
MDM - SFDM	PIK 1	srednje vrijeme prolaska trasera	t_0	h	48,76
		efektivna brzina	v	cm/s	1,51
		long. Disperzija	D_L	m^2/h	371,81
		disperzivnost	α	m	6,85
		pecletov broj	Pe	-	386,63
		difuzija u matriks	a	$h^{-0.5}$	0,00220
	PIK 2	srednje vrijeme prolaska trasera	t_0	h	218,13
		efektivna brzina	v	cm/s	0,34
		long. Disperzija	D_L	m^2/h	9012,95
		disperzivnost	α	m	742,57
		pecletov broj	Pe	-	3,57
		difuzija u matriks	a	$h^{-0.5}$	0,00401
2RNE		srednje vrijeme prolaska trasera	t_0	h	58,83
		efektivna brzina	v	cm/s	1,25
		long. Disperzija	D_L	m^2/h	306,30
		disperzivnost	α	m	6,81
		pecletov broj	Pe	-	388,96
		koeficijent udjela mobilne i nemobilne zone	β	-	0,85
		koeficijent priijenosa mase	ω	-	0,20

7.4.4.2.1 Metoda momenata s Chatwinovom metodom

Srednje vrijeme prolaska trasera je metodom momenata određeno na 68,78 sati što daje srednju brzinu prolaska trasera od 1,07 cm/s.

Chatwinovom metodom je longitudinalna disperzija procijenjena na 560,77 m²/h ili izraženo kroz disperzivnost 14,57 m. Pecletov broj prema tome iznosi 181,72 (Slika 7.32).




Slika 7.32. Izračun Chatwinovog parametra za trasiranje uraninom izvedeno u veljači 2012. godine

Volumen kanala koji sudjeluju u toku procijenjen je na 24 075 m³. Pretpostavljajući cilindričnost kanala, površina njegovog presjeka iznosi 9,09 m² što daje polumjer od 1,7 m.

7.4.4.2.2 Equilibrium CDE – ravnotežni konvekcijsko-disperzijski model

Modeliranje CDE modelom je dalo srednje vrijeme prolaska uranina od 50 sati. Preračunato u srednju brzinu to iznosi 1,47 cm/s (Slika 7.33).




Slika 7.33. Rezultati CDE modela za trasiranje uraninom izvedeno u veljači 2012. godine

Longitudinalna disperzija je procijenjena na 458,1 m²/h. Iz toga se može izračunati disperzivnost od 8,65 m i Pecletov broj 305,96.

7.4.4.2.3 SFDM i MDM – jednopukotinski model disperzije i multidisperzijski model

Obzirom da su rezultati SFDM modela identični s rezultatima prve krivulje MDM modela, njihovi rezultati će biti prikazani zajedno. Pri tome rezultati 1. krivulje MDM modela predstavljaju ujedno i rezultate SFDM modela (Slika 7.34).




Slika 7.34. Rezultati SFDM i MDM modela za trasiranje uraninom izvedeno u veljači 2012. godine

Srednje vrijeme prolaska uranina po SFDM modelu i prvoj krivulji MDM modela je 48,76 sati tj. preračunato u brzinu 1,51 cm/s. Longitudinalna disperzija je procijenjena na 458,1 m²/h. Prema tome disperzivnost iznosi 6,85 m, dok je Pecletov broj 386,63. Difuzija u matriks je procijenjena na 0,0022 h^{-0,5}.

Druga modelirana krivulja MDM modela u glavniini simulira rep opažane krivulje koncentracije. Njeno srednje vrijeme je 218,13 sati što daje srednju brzinu od 0,34 cm/s. Longitudinalna disperzija je 9012,95 m²/h, dok je disperzivnost 742,57 m i Pecletov broj 3,57. Difuzija u matriks je procijenjena na 0,00401 h^{-0,5}.

7.4.4.2.4 2RNE – neravnotežni dvo-zonski model

Srednje vrijeme prolaska uranina procijenjeno je na 58,83 sati. Preračunato u brzinu dobivamo 1,25 cm/s (Slika 7.35). Longitudinalna disperzija iznosi 306,3 m²/h što daje disperzivnost od 6,81 m i Pecletov broj u vrijednosti od 388,96.




Slika 7.35. Rezultati 2RNE modela za trasiranje uraninom izvedeno u veljači 2012. godine

Koeficijent udjela mobilne i nemobilne zone iznosi 0,85, dok je koeficijent prijenosa mase 0,2.

7.4.5 Trasiranje ponora P-2 izvedeno 23. veljače 2012. godine

Trasiranje ponora P-2 je izvršeno 23. veljače 2012. godine u 13 sati sa 3000 grama naftionata. Simultano je izvedeno trasiranje ponora P-1 (opisano u poglavlju 7.4.4).

Hidrološki uvjeti na izvoru Jaža su bili identični kao i tijekom prethodno opisanog trasiranja obzirom da su izvedena simultano. Uvjeti na ponoru P-2 su bili nešto drukčiji nego u slučaju ponora P-1. Vodni val je na ponor P-2 naišao nešto kasnije, te je traser ubačen prije njegovog nailaska (Slika 7.36).




Slika 7.36. Protok vode na ponoru P-2 u razdoblju od 1. veljače 2012. godine, pa do kraja istjecanja trasera i količina oborina na najbližem kišomjeru u Radinoj Vasi

7.4.5.1 Osnovni parametri

Pojava naftionata je zabilježena isključivo na izvoru Jaža. Krivulja koncentracije naftionata je vrlo slična krivulji uranina. Odlikuje je vrlo izražen pik relativno kratkog trajanja i vrlo dugačak rep niske koncentracije. Početak repa krivulje je u slučaju naftionata je nešto izraženiji (Slika 7.37).

Naftionat je na izvor Jažu došao malo nakon uranina i vrlo dobro se poklopio s najizdašnjim dijelom vodnog vala.



Slika 7.37. Krivulja koncentracije trasera (naftionata) i protoka na izvoru Jaža

Pojava trasera je na izvoru zabilježena nakon nešto više od 43 sata dok je maksimalna koncentracija zabilježena nakon nešto više od dva i pol dana. Ukupno trajanje istjecanja trasera je bilo nešto preko 24 dana. U tom razdoblju je zabilježen izlazak 90,95 % ubačenog naftionata (Tablica 7.9).

Tablica 7.9. Osnovni parametri trasiranja ponora P-2 izvedenog u veljači 2012. godine. Prividne brzine su izračunate pomoću korigirane udaljenosti

Podzemna veza	Pravocrtna udaljenost (m)	Korigirana udaljenost (m)	Visinska razlika (m)	Vrijeme do prve pojave (sati)	Prividna brzina prve pojave (cm/s)
P-2 - Jaža	2110	3165	140	43,25	2,03
Podzemna veza	Maksimalna koncentracija (µg/l)	Vrijeme do pojave maks. konc. (sati)	Prividna brzina maks. konc. (cm/s)	Vrijeme zadnje pojave (dani)	Pronos (%)
P-2 - Jaža	266,27	62	1,42	26,02	90,95

Ukoliko bi brzinu prvog nailaska trasera izračunali pomoću pravocrtna udaljenosti ponora P-2 od izvora Jaže, njen iznos bi bio 1,36 cm/s.

7.4.5.2 Modelirani parametri

Tablica 7.10 prikazuje rezultate svih modela za trasiranje naftionatom.

Tablica 7.10. Rezultati modela za parametre toka i transporta trasiranja izvedenog u veljači 2012. godine


MODEL		SVOJSTVO	SIMBOL	JEDINICA	P-1 - JAŽA
metoda momenata s Chatwinovom metodom		srednje vrijeme prolaska trasera	t_0	h	77,17
		efektivna brzina	v	cm/s	1,14
		long. Disperzija	D_L	m^2/h	638,89
		disperzivnost	α	m	15,58
		pecletov broj	Pe	-	203,18
CDE*		srednje vrijeme prolaska trasera	t_0	h	63,94
		efektivna brzina	v	cm/s	1,38
		long. Disperzija	D_L	m^2/h	595,40
		disperzivnost	α	m	12,03
		pecletov broj	Pe	-	263,13
SFDM		srednje vrijeme prolaska trasera	t_0	h	62,18
		efektivna brzina	v	cm/s	1,41
		long. Disperzija	D_L	m^2/h	457,01
		disperzivnost	α	m	8,98
		pecletov broj	Pe	-	352,54
		difuzija u matriks	a	$h^{-0.5}$	0,00110
MDM - SFDM	PIK 1	srednje vrijeme prolaska trasera	t_0	h	62,18
		efektivna brzina	v	cm/s	1,41
		long. Disperzija	D_L	m^2/h	457,01
		disperzivnost	α	m	8,98
		pecletov broj	Pe	-	352,54
		difuzija u matriks	a	$h^{-0.5}$	0,00110
	PIK 2	srednje vrijeme prolaska trasera	t_0	h	141,58
		efektivna brzina	v	cm/s	0,62
		long. Disperzija	D_L	m^2/h	11571,72
		disperzivnost	α	m	517,64
		pecletov broj	Pe	-	6,11
		difuzija u matriks	a	$h^{-0.5}$	0,00272
2RNE		srednje vrijeme prolaska trasera	t_0	h	117,22
		efektivna brzina	v	cm/s	0,75
		long. Disperzija	D_L	m^2/h	254,10
		disperzivnost	α	m	9,41
		pecletov broj	Pe	-	336,30
		koeficijent udjela mobilne i nemobilne zone	β	-	0,54
		koeficijent priijenosa mase	ω	-	0,79

* - modelirana ulazna masa trasera

7.4.5.2.1 Metoda momenata s Chatwinovom metodom

Srednje vrijeme prolaska naftionata je metodom momenata izračunato na 77,17 sati. Pomoću toga je srednja brzina određena na 1,14 cm/s.

Longitudinalna disperzija je Chatwinovom metodom procijenjena na 638,89 m²/h, a na temelju toga je disperzivnost izračunata na 15,58 m i Pecletov broj na 203,18 (Slika 7.38).




Slika 7.38. Izračun Chatwinovog parametra za trasiranje naftionatom izvedeno u veljači 2012. godine

Volumen kanala koji sudjeluju u toku je procijenjen na 28 118 m³. Poprečni presjek cilindričnog kanala bi prema tome iznosio 8,88 m² i imao bi polumjer od 1,68 m.

7.4.5.2.2 Equilibrium CDE – ravnotežni konvekcijsko-disperzijski model

Zadovoljavajuće preklapanje modelirane i opažane krivulje koncentracije je postignuto tek modeliranjem ulazne mase ubačenog trasera. Umjesto ubačenih 3000 grama naftionata, modelom je pretpostavljeno 1632,26 grama.

Srednja brzina prolaska trasera je određena na 1,38 cm/s, a longitudinalna disperzija na 595,4 m²/h (Slika 7.39).




Slika 7.39. Rezultati CDE modela za trasiranje naftionatom izvedeno u veljači 2012. godine

Iz dobivenih parametara može se izračunati disperzivnost koja iznosi 12,03 m, te Pecletov broj 263,13.

7.4.5.2.3 SFDM i MDM – jednopukotinski model disperzije i multidisperzijski model

Rezultati SFDM modela se poklapaju s rezultatima prve krivulje MDM modela. Iz tog razloga će njihovi rezultati biti prikazani skupa (Slika 7.40).




Slika 7.40. Rezultati SFDM i MDM modela za trasiranje naftionatom izvedeno u veljači 2012. godine

Srednje vrijeme SFDM modela tj. prve krivulje MDM modela je 62,18 sati što daje srednju efektivnu brzinu od 1,41 cm/s. Longitudinalna disperzija je 457,01 m²/h iz čega proizlazi da je disperzivnost 8,98 m, a Pecletov broj 352,54. Difuzija u matriks iznosi 0,0011 h^{-0,5}.

Druga krivulja ima srednje vrijeme 141,58 sati i srednju efektivnu brzinu 0,62 cm/s. Longitudinalna disperzija iznosi 11571,72 m²/h, što daje disperzivnost od 517,64 m i Pecletov broj 6,11. Difuzija u matriks iznosi 0,00272 h^{-0,5}.

7.4.5.2.4 2RNE – neravnotežni dvo-zonski model

Srednje vrijeme prolaska naftionata je 2RNE modelom procijenjeno na 117,22 sata tj. srednja efektivna brzina je 0,75 cm/s (Slika 7.41). Longitudinalna disperzija iznosi 254,1 m²/h što daje disperzivnost od 9,41 m i Pecletov broj u vrijednosti od 336,3.



Slika 7.41. Rezultati 2RNE modela za trasiranje naftionatom izvedeno u veljači 2012. godine

Koeficijent udjela mobilne i nemobilne zone iznosi 0,54, dok je koeficijent prijenosa mase 0,79.


7.4.6 Trasiranje Jamine pod Piskom izvedeno 26. lipnja 2012. godine

Trasiranje Jamine pod Piskom izvršeno je 26. lipnja 2012. godine u 14 sati ubacivanjem 500 grama uranina. Obzirom da se radi o speleološkom objektu bez vode, ista se dopremila putem vatrogasnih crijeva od najbližeg hidranta. U jamu je utisnuto otprilike 70 m³ vode.

Dva dana kasnije izvršeno je trasiranje ponora P-1 s naftionatom. Iako traseri nisu ubačeni u isto vrijeme, hidrološki uvjeti su bili gotovo identični jer se radilo o periodu malih voda s malom promjenom dinamike.

Trasiranje je izvršeno nakon što su protoci na izvorima Jaža i Obrv pali nakon posljednjih većih kiša. U trenutku ubacivanja trasera u jamu, na izvoru Obrv je


istjecalo otprilike 25 l/s vode. Protok je kontinuirano padao do najniže vrijednosti od 4,5 l/s usprkos nekoliko kišnih dana tijekom srpnja. Tek krajem kolovoza je došlo do sporadičnih, ali obilnih kiša koje su poremetile period malih voda (Slika 7.42).



Slika 7.42. Protok vode na izvoru Obrv u razdoblju od 1. lipnja 2012. godine, pa do kraja istjecanja trasera i količina oborina na najbližem kišomjeru u Gornjem Oštrcu

7.4.6.1 Osnovni parametri

Uranin ubačen u Jaminu pod Piskom zabilježen je isključivo na izvoru Obrv. Krivulju koncentracije trasera obilježavaju dva izrazita pika s relativno niskom koncentracijom između (Slika 7.43). Pri tome maksimalna koncentracija dolazi tek u drugom piku, čak dva mjeseca nakon ubacivanja trasera.



Slika 7.43. Krivulja koncentracije trasera (uranina) i protoka na izvoru Obrv

Prva pojava uranina zabilježena je nakon skoro deset dana od vremena ubacivanja (Tablica 7.11). Prvi pik s maksimalnom koncentracijom od 5,04 µg/l zabilježen je nakon više od 16 dana. Prvi pik se za otprilike 28 dana spustio na razinu od približno 1 µg/l i tako istjecao narednih 24 dana. Tek tada je koncentracija porasla na maksimalnu zabilježenu koncentraciju od 11,21 µg/l, nakon više od 62 dana nakon ubacivanja trasera. Zabilježeni pronos je usprkos dugom opažanju samo 33,38 %.

Tablica 7.11. Osnovni parametri trasiranja Jamine pod Piskom izvedenog u lipnju 2012. godine. Prividne brzine su izračunate pomoću korigirane udaljenosti

Podzemna veza	Pravocrtna udaljenost (m)	Korigirana udaljenost (m)	Visinska razlika (m)	Vrijeme do prve pojave (sati)	Prividna brzina prve pojave (cm/s)
jama - Obrv	2175	3262,5	130	238,88	0,38
Podzemna veza	Maksimalna koncentracija (µg/l)	Vrijeme do pojave maks. konc. (sati)	Prividna brzina maks. konc. (cm/s)	Vrijeme zadnje pojave (dani)	Pronos (%)
jama - Obrv	11,21	1506,4	0,06	79	33,38

Kad bi prividnu brzinu prve pojave trasera izračunali pomoću pravocrtnne udaljenosti, njen iznos bi bio 0,25 cm/s.

7.4.6.2 Modelirani parametri

Tablica 7.12 prikazuje rezultate svih modela za trasiranje uraninom. Obzirom na specifičnost opažane krivulje koncentracije s dva pika, primijenjena su samo dva modela. Metoda momenata koja statistički obrađuje cijelu krivulju, te MDM model koji jedini ima mogućnost modeliranja više krivulja.


Tablica 7.12. Rezultati modela za parametre toka i transporta trasiranja izvedenog u lipnju 2012. godine

MODEL		SVOJSTVO	SIMBOL	JEDINICA	jama - OBRV
metoda momenata s Chatwinovom metodom		srednje vrijeme prolaska trasera	t_0	h	1236,60
		efektivna brzina	v	cm/s	0,07
		long. Disperzija	D_L	m^2/h	39,15
		disperzivnost	α	m	14,84
		pecletov broj	Pe	-	219,84
MDM - SFDM	PIK 1	srednje vrijeme prolaska trasera	t_0	h	468,35
		efektivna brzina	v	cm/s	0,19
		long. Disperzija	D_L	m^2/h	707,33
		disperzivnost	α	m	101,54
		pecletov broj	Pe	-	32,13
		difuzija u matriks	a	$h^{-0.5}$	0,00181
	PIK 2	srednje vrijeme prolaska trasera	t_0	h	1033,00
		efektivna brzina	v	cm/s	0,09
		long. Disperzija	D_L	m^2/h	151,73
		disperzivnost	α	m	48,04
		pecletov broj	Pe	-	67,91
		difuzija u matriks	a	$h^{-0.5}$	0,00249
	PIK 3	srednje vrijeme prolaska trasera	t_0	h	1431,59
		efektivna brzina	v	cm/s	0,06
		long. Disperzija	D_L	m^2/h	12,79
		disperzivnost	α	m	5,61
		pecletov broj	Pe	-	581,14
		difuzija u matriks	a	$h^{-0.5}$	0,00385

7.4.6.2.1 Metoda momenata s Chatwinovom metodom

Metodom momenata je dobiveno srednje vrijeme prolaska trasera od 1236,6 sati tj. nešto više od 51 dan. S korigiranom udaljenošću srednja brzina iznosi 0,07 cm/s.

Longitudinalna disperzija je Chatwinovom metodom određena na 39,15 m²/h (Slika 7.44). Iz toga slijedi da disperzivnost iznosi 14,84 m i Pecletov broj 219,84.




Slika 7.44. Izračun Chatwinovog parametra za trasiranje uraninom izvedeno u lipnju 2012. godine

Pomoću srednjeg vremena prolaska uranina je napravljena procjena volumena kanala koja iznosi 45 059 m³. Pod pretpostavkom da postoji jedan cilindričan kanal, površina njegovog poprečnog presjeka bi iznosila 13,811 m², dok bi mu polumjer bio 2,01 m.

7.4.6.2.2 MDM – multidisperzijski model

MDM modelom je opažana krivulja simulirana pomoću tri zasebne krivulje koncentracije (Slika 7.45).



Slika 7.45. Rezultati MDM modela za trasiranje uraninom izvedeno u lipnju 2012. godine

Prva krivulja se odnosi na prvi pik i srednje vrijeme dobiveno pomoću nje iznosi 468,35 sati. Preračunato u brzinu dobiva se 0,19 cm/s. Longitudinalna disperzija iznosi 707,33 m²/h, iz čega se može izračunati disperzivnost od 101,54 m i Pecletov broj 32,13. Difuzija u matriks je izračunata u iznosu od 0,00181 h^{-0,5}. Obzirom na specifičnu krivulju koncentracije trasera, volumen kanala koji su sudjelovali u toku je u slučaju ovog trasiranja iznimno napravljen i za prvu krivulju MDM modela. Prema tome, volumen kanala bi bio 21 444 m³, a površina njegovog presjeka bi u slučaju pravilnog cilindričnog oblika iznosila 6,573 m² i imao bi polumjer od 1,45 m.

Druga krivulja u najvećem dijelu pokriva vrijeme između dva izrazita pika na opažanoj krivulji koncentracije. Srednje vrijeme dobiveno pomoću nje iznosi 1033 sati ili preračunato u brzinu 0,09 cm/s. Longitudinalna disperzija je 151,73 m²/h iz čega


slijedi da je disperzivnost 48,04 m, a Pecletov broj 67,91. Difuzija u matriks druge krivulje je 0,00249.

Zadnja krivulja simulira zadnji, ujedno i najveći pik u opažanoj krivulji. Njeno srednje vrijeme je 1431,59 sati tj. više od 59 dana. Iz toga slijedi brzina od 0,06 cm/s. Longitudinalna disperzija je izračunata u vrijednosti od 12,79 m²/h, što daje disperzivnost od 5,61 m i Pecletov broj 581,14. Difuzija u matriks iznosi 0,00385.

7.4.7 Trasiranje ponora P-1 izvedeno 28. lipnja 2012. godine

Trasiranje ponora P-1 izvedeno je 28. lipnja 2012. godine u 11:15 sati. Za razliku od ostalih trasiranja ponora P-1 koja su izvedena s uraninom, ovom prigodom je ubačeno 3000 grama naftionata. Trasiranje je izvedeno dva dana nakon trasiranja Jamine pod Piskom. Obzirom na dugotrajno trajanje istjecanja trasera i stabilne hidrološke uvjete, može se smatrati da su trasiranja napravljena u istim hidrološkim uvjetima.


Traser je ubačen nakon što se razina vode spustila nakon zadnje veće kiše (Slika 7.46). Tijekom većeg dijela trasiranja je palo nešto kiše, ali ne dovoljno da značajno prekine recesiju. Tek pred kraj trasiranja je pala nešto značajnija količina kiše koja je podigla razinu vode izvoru Jaža.



Slika 7.46. Protok vode na ponoru P-1 u razdoblju od 1. lipnja 2012. godine, pa do kraja istjecanja trasea i količina oborina na najbližem kišomjeru u Radinoj Vasi

7.4.7.1 Osnovni parametri

Naftionat ubačen u ponor P-1 je zabilježen isključivo na izvoru Jaža. Cijelo vrijeme istjecanja trasea je bilo obilježeno stabilnim protokom na izvoru. Krivulja koncentracije trasea je izrazito pravilna. Pik je pravilan i blago asimetričan, a rep je relativno kratak i niske koncentracije (Slika 7.47).



Slika 7.47. Krivulja koncentracije trasera (naftionata) i protoka na izvoru Jaža

Prva pojava trasera zabilježena je 116,75 sati tj. nešto manje od pet dana nakon ubacivanja (Tablica 7.13). Maksimalna koncentracija od 289,97 µg/l zabilježena je nakon više od devet dana. Naftionat je na izvoru Jaža istjecao ukupno 23,5 dana.

Tablica 7.13. Osnovni parametri trasiranja ponora P-1 izvedenog u lipnju 2012. godine. Prividne brzine su izračunate pomoću korigirane udaljenosti

Podzemna veza	Pravocrtna udaljenost (m)	Korigirana udaljenost (m)	Visinska razlika (m)	Vrijeme do prve pojave (sati)	Prividna brzina prve pojave (cm/s)
P-1 - Jaža	1765	2647	110	116,75	0,63
Podzemna veza	Maksimalna koncentracija (µg/l)	Vrijeme do pojave maks. konc. (sati)	Prividna brzina maks. konc. (cm/s)	Vrijeme zadnje pojave (dani)	Pronos (%)
P-1 - Jaža	289,97	222,5	0,33	28,38	28,19

Prividna brzina prvog nailaska izračunata pomoću pravocrtna udaljenosti iznosi 0,42 cm/s.

7.4.7.2 Modelirani parametri

Tablica 7.14 prikazuje rezultate svih modela za trasiranje.


Tablica 7.14. Rezultati modela za parametre toka i transporta trasiranja izvedenog u lipnju 2012. godine

MODEL		SVOJSTVO	SIMBOL	JEDINICA	P-1 - JAŽA
metoda momenata s Chatwinovom metodom		srednje vrijeme prolaska trasera	t_0	h	239,88
		efektivna brzina	v	cm/s	0,31
		long. Disperzija	D_L	m^2/h	520,74
		disperzivnost	α	m	47,18
		pecletov broj	Pe	-	56,11
CDE*		srednje vrijeme prolaska trasera	t_0	h	238,51
		efektivna brzina	v	cm/s	0,31
		long. Disperzija	D_L	m^2/h	676,30
		disperzivnost	α	m	60,93
		pecletov broj	Pe	-	43,45
SFDM		srednje vrijeme prolaska trasera	t_0	h	224,22
		efektivna brzina	v	cm/s	0,33
		long. Disperzija	D_L	m^2/h	525,02
		disperzivnost	α	m	44,46
		pecletov broj	Pe	-	59,54
		difuzija u matriks	a	$h^{-0.5}$	0,00568
MDM - SFDM	PIK 1	srednje vrijeme prolaska trasera	t_0	h	224,22
		efektivna brzina	v	cm/s	0,33
		long. Disperzija	D_L	m^2/h	525,02
		disperzivnost	α	m	44,46
		pecletov broj	Pe	-	59,54
		difuzija u matriks	a	$h^{-0.5}$	0,00568
	PIK 2	srednje vrijeme prolaska trasera	t_0	h	244,30
		efektivna brzina	v	cm/s	0,30
		long. Disperzija	D_L	m^2/h	1083,69
		disperzivnost	α	m	100,00
		pecletov broj	Pe	-	26,48
		difuzija u matriks	a	$h^{-0.5}$	0,00536
2RNE*		srednje vrijeme prolaska trasera	t_0	h	239,81
		efektivna brzina	v	cm/s	0,31
		long. Disperzija	D_L	m^2/h	140,30
		disperzivnost	α	m	12,71
		pecletov broj	Pe	-	208,33
		koeficijent udjela mobilne i nemobilne zone	β	-	0,67
		koeficijent priijenosa mase	ω	-	6,02

* - modelirana ulazna masa trasera

7.4.7.2.1 Metoda momenata s Chatwinovom metodom

Srednje vrijeme prolaska naftionata je metodom momenata određeno na 239,88 sati tj. skoro deset dana. Preračunato u brzinu, to iznosi 0,31 cm/s. Longitudinalna disperzija je Chatwinovom metodom izračunata u iznosu od 520,74 m²/h, što daje disperzivnost od 47,18 m i Pecletov broj 56,11 (Slika 7.48).




Slika 7.48. Izračun Chatwinovog parametra za trasiranje naftionatom izvedeno u lipnju 2012. godine

Pomoću srednjeg vremena prolaska trasera je napravljena procjena volumena kanala koji sudjeluju u toku. Njihov volumen po tome iznosi 8 371,8 m³. Iz toga možemo izračunati dimenzije cilindričnog kanala površine poprečnog presjeka od 3,16 m² i polumjera od 1 metra.

7.4.7.2.2 Equilibrium CDE – ravnotežni konvekcijsko-disperzijski model

U slučaju ovog trasiranja nije bilo moguće doći do zadovoljavajućeg preklapanja modelirane i opažane krivulje koncentracije trasera. Prihvatljivo rješenje je dobiveno tek modeliranjem i ulazne mase ubačenog trasera. U skladu s time, ulazna masa naftionata je određena na samo 1326,71 grama, naspram 3000 grama naftionata koji je ubačen.

Prema CDE modelu, srednje vrijeme prolaska naftionata je procijenjeno na 238,51 sati tj. malo manje od deset dana (Slika 7.49). Srednja brzina u tom slučaju iznosi 0,31 cm/s.




Slika 7.49. Rezultati CDE modela za trasiranje naftionatom izvedeno u lipnju 2012. godine

Longitudinalna disperzija je procijenjena u iznosu od $676,30 \text{ m}^2/\text{h}$. U skladu s time, disperzivnost iznosi 60,93 m, a Pecletov broj 43,45.

7.4.7.2.3 SFDM i MDM – jednopukotinski model disperzije i multidisperzijski model

Rezultati SFDM modela se poklapaju s prvom krivuljom MDM modela te će biti prikazani zajedno (Slika 7.50).

Srednje vrijeme prve krivulje je procijenjeno na 224,22 sata što daje srednju brzinu od 0,33 cm/s. Iznos longitudinalne disperzije je 525,02 m²/h iz čega slijedi da je iznos disperzivnosti 44,46 m, a Pecletov broj 59,54. Difuzija u matriks iznosi 0,005568 h^{-0,5}.



Slika 7.50. Rezultati SFDM i MDM modela za trasiranje naftionatom izvedeno u lipnju 2012. godine


Druga modelirana krivulja ima srednje vrijeme prolaska trase od 244,30 sati tj. malo više od 10 dana. Srednja efektivna brzina iznosi 0,30 cm/s, dok je longitudinalna disperzija 1083,69 m²/h. Disperzivnost u tom slučaju iznosi 100 m, dok je Pecletov broj 26,48. Difuzija u matriks iznosi 0,005536 h^{-0,5}.

7.4.7.2.4 2RNE – neravnotežni dvo-zonski model

Prilikom modeliranja u 2RNE modelu je došlo do istih problema kao i u CDE modelu. Za zadovoljavajuće preklapanje krivulja opažane i modelirane koncentracije je bilo neophodno modelirati i ulaznu masu naftionata. U ovom slučaju je ulazna masa određena na 1322,95 grama naspram ubačenih 3000 grama naftionata.

Treba napomenuti da je u ovom slučaju moguće dobiti rješenje gotovo identično CDE modelu. Smanjivanjem udjela i utjecaja nemobilne zone dobiva se zapravo CDE model koji ima zadovoljavajuće preklapanje opažane i modelirane krivulje koncentracije. Odabrano je rješenje koje daje gotovo identičnu krivulju, ali različite parametre.

Srednje vrijeme prolaska naftionata je 2RNE modelom procijenjeno na 239,81 sati. Preračunato u srednju efektivnu brzinu dobije se brzina od 0,31 cm/s (Slika 7.51). Longitudinalna disperzija ispada 140,30 m²/h, što daje disperzivnost od 12,71 m i Pecletov broj 208,33.




Slika 7.51. Rezultati 2RNE modela za trasiranje naftionatom izvedeno u lipnju 2012. godine

Koeficijent udjela mobilne i nemobilne zone je 0,67, dok je koeficijent prijenosa mase 6,02.

7.4.8 Trasiranje ponora P-2 izvedeno 16. listopada 2012. godine


Naftionat je ubačen u ponor P-2 16. listopada 2012. godine u 12 sati. Ubačeno je 3000 grama naftionata kao i kod prethodnih trasiranja. Sat vremena kasnije izvršeno je ubacivanje uranina u ponor P-1. Traser je ubačen u periodu srednjih voda, ali u vrhu velikog vodnog vala. Radi toga su uvjeti tečenja tijekom trasiranja bili sličniji uvjetima visokih voda (Slika 7.52). Prva polovica trajanja istjecanja trasera je prošla bez oborina, dok je u drugoj polovici došlo da više manjih, ali učestalih kiša koje su uzrokovala nove vodne valove.



Slika 7.52. Protok vode na ponoru P-2 u razdoblju od 1. listopada 2012. godine, pa do kraja istjecanja trasera i količina oborina na najbližem kišomjeru u Radinoj Vasi. Maksimalni protok nedostaje jer je u tim uvjetima protok nemoguće izmjeriti.

7.4.8.1 Osnovni parametri

Pojava naftionata je zabilježena isključivo na izvoru Jaža. Krivulja koncentracije trasera se sastoji od tri odvojena pika (Slika 7.53). Prvi i ujedno glavni pik se najvećim dijelom nalazi unutar vodnog vala na Jaži. Nakon toga slijedi relativno dugi rep niske koncentracije. Dva naredna pika su značajno manje koncentracije i trajanja od prvog. Njihova pojava je uzrokovana nadolaskom vodnih valova uzrokovanih kišama koje su pale tijekom druge polovice trajanja istjecanja trasera (Slika 7.52).



Slika 7.53. Krivulja koncentracije trasera (naftionata) i protoka na izvoru Jaža

Naftionat je na izvor Jažu došao brže nego prilikom svih drugih trasiranja izvedenih u sklopu ovog istraživanja. Prva pojava je zabilježena već nakon 4 sata nakon ubacivanja u ponor što daje brzinu prvog nailaska od skoro 22 cm/s (računajući s korigiranom udaljenošću) (Tablica 7.15). Maksimalna koncentracija je izmjerena 11 sati nakon ubacivanja trasera i iznosila je 179,25 µg/l. Kraj istjecanja trećeg pika, a time i ukupnog trasera zabilježeno je nakon više od 18 dana od ubacivanja trasera.

Tablica 7.15. Osnovni parametri trasiranja ponora P-2 izvedenog u listopadu 2012. godine. Prividne brzine su izračunate pomoću korigirane udaljenosti

Podzemna veza	Pravocrtna udaljenost (m)	Korigirana udaljenost (m)	Visinska razlika (m)	Vrijeme do prve pojave (sati)	Prividna brzina prve pojave (cm/s)
P-2 - Jaža	2110	3165	140	4	21,98
Podzemna veza	Maksimalna koncentracija (µg/l)	Vrijeme do pojave maks. konc. (sati)	Prividna brzina maks. konc. (cm/s)	Vrijeme zadnje pojave (dani)	Pronos (%)
P-2 - Jaža	179,25	11	7,99	18,27	97,93

Prividna brzina prvog nailaska izračunata pomoću linearne udaljenosti iznosi 14,65 cm/s.

7.4.8.2 Modelirani parametri

Tablica 7.16 prikazuje rezultate svih modela za trasiranje. Treba napomenuti da su svi modeli osim MDM modela rađeni isključivo na prvom dijelu krivulje, odnosno na prvom pik. Obradivanje cijele krivulje bi uzrokovalo pogrešne parametre obzirom da su naknadni pikovi uzrokovani novim vodnim valovima. Jedino je MDM modelom moguće pokušati i njih uključiti u model jer ih se može izolirati od glavne krivulje. U suprotnom bi došlo do osrednjavanja parametara svih krivulja što bi rezultiralo pogrešnim rezultatom.

Tablica 7.16. Rezultati modela za parametre toka i transporta trasiranja izvedenog u listopadu 2012. godine


MODEL		SVOJSTVO	SIMBOL	JEDINICA	P-2 - JAŽA
metoda momenata s Chatwinovom metodom		srednje vrijeme prolaska trasera	t_0	h	19,00
		efektivna brzina	v	cm/s	4,63
		long. Disperzija	D_L	m^2/h	35577,72
		disperzivnost	α	m	213,60
		pecletov broj	Pe	-	14,82
CDE*		srednje vrijeme prolaska trasera	t_0	h	13,44
		efektivna brzina	v	cm/s	6,54
		long. Disperzija	D_L	m^2/h	34960,00
		disperzivnost	α	m	148,45
		pecletov broj	Pe	-	21,32
SFDM		srednje vrijeme prolaska trasera	t_0	h	12,25
		efektivna brzina	v	cm/s	7,18
		long. Disperzija	D_L	m^2/h	32914,35
		disperzivnost	α	m	127,42
		pecletov broj	Pe	-	24,84
		difuzija u matriks	a	$h^{-0.5}$	0,00262
MDM - SFDM	PIK 1	srednje vrijeme prolaska trasera	t_0	h	12,25
		efektivna brzina	v	cm/s	7,18
		long. Disperzija	D_L	m^2/h	32914,35
		disperzivnost	α	m	127,42
		pecletov broj	Pe	-	24,84
		difuzija u matriks	a	$h^{-0.5}$	0,00262
	PIK 2	srednje vrijeme prolaska trasera	t_0	h	67,74
		efektivna brzina	v	cm/s	1,30
		long. Disperzija	D_L	m^2/h	34803,29
		disperzivnost	α	m	744,93
		pecletov broj	Pe	-	4,25
		difuzija u matriks	a	$h^{-0.5}$	0,01859
	PIK 3	srednje vrijeme prolaska trasera	t_0	h	151,08
		efektivna brzina	v	cm/s	0,58
		long. Disperzija	D_L	m^2/h	1094,30
		disperzivnost	α	m	52,24
		pecletov broj	Pe	-	60,59
		difuzija u matriks	a	$h^{-0.5}$	0,00675
	PIK 4	srednje vrijeme prolaska trasera	t_0	h	283,90
		efektivna brzina	v	cm/s	0,31
		long. Disperzija	D_L	m^2/h	2,85
		disperzivnost	α	m	0,26
		pecletov broj	Pe	-	12377,92
		difuzija u matriks	a	$h^{-0.5}$	0,00122
	PIK 5	srednje vrijeme prolaska trasera	t_0	h	268,79
		efektivna brzina	v	cm/s	0,33
		long. Disperzija	D_L	m^2/h	1,23
		disperzivnost	α	m	0,10
		pecletov broj	Pe	-	30389,80
		difuzija u matriks	a	$h^{-0.5}$	0,02932
2RNE*		srednje vrijeme prolaska trasera	t_0	h	19,00
		efektivna brzina	v	cm/s	4,63
		long. Disperzija	D_L	m^2/h	11800,00
		disperzivnost	α	m	70,83
		pecletov broj	Pe	-	44,69
		koeficijent udjela mobilne i nemobilne zone	β	-	0,63
		koeficijent prijenosa mase	ω	-	0,72

* - modelirana ulazna masa trasera

7.4.8.2.1 Metoda momenata s Chatwinovom metodom

Metodom momenata je obrađen kompletni prvi pik krivulje s repom, ali bez naknadna dva pika uzrokovana novim vodnim valovima.

Dobiveno srednje vrijeme prolaska trasera je 19 sati, što daje srednju efektivnu brzinu od 4,63 cm/s. Longitudinalna disperzija je procijenjena na 35577,72 m²/h (Slika 7.54). Iz toga se može zaključiti da je disperzivnost 213,6 m, a Pecletov broj 14,82.




Slika 7.54. Izračun Chatwinovog parametra za trasiranje naftionatom izvedeno u listopadu 2012. godine

Ukupni volumen kanala koji sudjeluju u toku je procijenjen na 41282 m³. Pretpostavljajući cilindričan oblik kanala dobili bi kanal površine poprečnog presjeka 13,04 m² i polumjera 2,04 metra.

7.4.8.2.2 Equilibrium CDE – ravnotežni konvekcijsko-disperzijski model

Prilikom modeliranja CDE modelom u obzir je uzet samo prvi dio krivulje s glavnim pikom. Za uspješno preklapanje modelirane i opažane krivulje koncentracije trasera bilo je neophodno modelirati i ulaznu količinu trasera. Tako je umjesto ulazne količine naftionata od 3000 g uzeto 5437,85 g.

Srednje vrijeme prema CDE modelu je 13,44 sati uz srednju efektivnu brzinu prolaska trasera od 6,54 cm/s. Longitudinalna disperzija je procijenjena na 34960 m²/h što daje disperzivnost od 148,45 m i Pecletov broj 21,32 (Slika 7.55).




Slika 7.55. Rezultati CDE modela za trasiranje naftionatom izvedeno u listopadu 2012. godine

7.4.8.2.3 SFDM i MDM – jednopukotinski model disperzije i multidisperzijski model

Rezultati SFDM modela se poklapaju s prvom krivuljom MDM modela te će biti prikazani zajedno (Slika 7.56).

Jedino MDM modelom je bilo pokušano modeliranje kompletne opažane krivulje koncentracije trasera tj. glavnog pika i dva naredna pika. Za to je bilo potrebno izdvojiti čak pet zasebnih krivulja koncentracije.



Slika 7.56. Rezultati SFDM i MDM modela za trasiranje naftionatom izvedeno u listopadu 2012. godine

Srednje vrijeme prve krivulje je 12,25 sati što daje srednju efektivnu brzinu od 7,18 cm/s. Longitudinalna disperzija je 32914,35 m²/h dok je disperzivnost 127,42 m i Pecletov broj 24,84. Difuzija u matriks je 0,00262 h^{-0,5}.

Druga krivulja ima srednje vrijeme prolaska trasera 67,74 sati ili preračunato u brzinu, 1,3 cm/s. Longitudinalna disperzija je procijenjena na 34803,29 m²/h. Preračunato u disperzivnost dobije se 744,93 m tj. Pecletov broj 4,25. Difuzija u matriks je 0,01859 h^{-0,5}.

Treća krivulja ima srednje vrijeme 151,08 sati odnosno brzinu 0,58 cm/s. Longitudinalna disperzija iznosi 1094,3 m²/h, dok je disperzivnost 52,24 m, a Pecletov broj 60,59. Difuzija u matriks je procijenjena na 0,00675 h^{-0,5}.


Četvrta krivulja ima srednje vrijeme 283,9 sati ili izraženo kao brzina 0,31 cm/s. Longitudinalna disperzija je 2,85 m²/h što daje disperzivnost od 0,26 m i Pecletov broj 12377,92. Difuzija u matriks je 0,00122 h^{-0,5}.

Posljednja, peta krivulja, ima srednje vrijeme 268,79 sati tj. srednju efektivnu brzinu 0,33 cm/s. Longitudinalna disperzija iznosi 1,23 m²/h, a disperzivnost je 0,1 m i Pecletov broj je 30389,8. Difuzija u matriks iznosi 0,02932 h^{-0,5}.

7.4.8.2.4 2RNE – neravnotežni dvo-zonski model

Prilikom primjene 2RNE modela je bilo potrebno u modelirane parametre staviti i masu trasera kao i u slučaju CDE modela. U skladu s time, ulazna masa naftionata je 6908,95 g umjesto 3000 g. U obzir je uzet samo prvi dio krivulje, bez zadnja dva pika (Slika 7.57).

Srednje vrijeme s 2RNE modelom je određeno na 19 sati. Izraženo preko srednje efektivne brzine to daje 4,63 cm/s.




Slika 7.57. Rezultati 2RNE modela za trasiranje naftionatom izvedeno u listopadu 2012. godine

Longitudinalna disperzija je procijenjena na 11800 m²/h, dok je disperzivnost 70,83 m i Pecletov broj 44,69. Koeficijent udjela mobilne i nemobilne zone je 0,63, a koeficijent prijenosa mase je 0,72.

7.4.9 Trasiranje ponora P-1 izvedeno 16. listopada 2012. godine


Trasiranje je izvršeno ubacivanjem 100 grama uranina u ponor P-1, 16. listopada 2012. godine u 13 sati. Samo jedan sat ranije je ubačen naftionat u ponor P-2, tako da su hidrološki uvjeti tijekom ta dva trasiranja vrlo slični. Kao i u prethodno opisanom trasiranju, traser je ubačen u vrh vodnog vala tako da su uvjeti tečenja istovjetni uvjetima visokih voda (Slika 7.58). Rezultati trasiranja potvrđuju tu pretpostavku.



Slika 7.58. Protok vode na ponoru P-1 u razdoblju od 1. listopada 2012. godine, pa do kraja istjecanja traser i količina oborina na najbližem kišomjeru u Radinoj Vasi. Maksimalni protok nedostaje jer je u tim uvjetima protok nemoguće izmjeriti.

7.4.9.1 Osnovni parametri

Uranin je kao i kod svih prethodnih trasiranja ponora P-1 zabilježen isključivo na izvoru Jaža. Krivulja koncentracije trasera je slična krivulji naftionata ubačenog u ponor P-2. Krivulja se sastoji od tri pika koji su povezani s nadolaskom vodnih valova. Prvi pik je dominantni i sadrži najveći dio ubačenog trasera (Slika 7.59).



Slika 7.59. Krivulja koncentracije trasera (uranina) i protoka na izvoru Jaža

Prvi nailazak uranina je na izvoru Jaža zabilježen već nakon 5,75 sati nakon ubacivanja. Prividna brzina prvog nailaska je bila 12,79 cm/s. Maksimalna koncentracija je iznosila 6,29 µg/l. Pojavila se za 7,5 sati što znači da je njena prividna brzina bila 9,81 cm/s. Zadnja pojava trasera je zabilježena nakon nešto više od 18 dana nakon ubacivanja u ponor P-1 (Tablica 7.17).

Tablica 7.17. Osnovni parametri trasiranja ponora P-1 izvedenog u listopadu 2012. godine. Prividne brzine su izračunate pomoću korigirane udaljenosti

Podzemna veza	Pravocrtna udaljenost (m)	Korigirana udaljenost (m)	Visinska razlika (m)	Vrijeme do prve pojave (sati)	Prividna brzina prve pojave (cm/s)
P-1 - Jaža	1765	2647,5	110	5,75	12,79
Podzemna veza	Maksimalna koncentracija (µg/l)	Vrijeme do pojave maks. konc. (sati)	Prividna brzina maks. konc. (cm/s)	Vrijeme zadnje pojave (dani)	Pronos (%)
P-1 - Jaža	6,29	7,5	9,81	18,27	104,29

U slučaju da prividnu brzinu prvog nailaska računamo pomoću pravocrtna udaljenosti ponora i izvora, njen iznos je 8,53 cm/s.

7.4.9.2 Modelirani parametri

Tablica 7.18 prikazuje rezultate svih modela za trasiranje. Kao i kod prethodno opisanog trasiranja ponora P-2 s naftionatom, i u ovom slučaju je došlo da naknadnih manjih pikova koncentracije trasera koji nisu uzeti u obzir kod modeliranja. Iznimka je MDM model koji omogućava rastavljanje cijele krivulje koncentracije na više zasebnih.

Tablica 7.18. Rezultati modela za parametre toka i transporta trasiranja izvedenog u listopadu 2012. godine


MODEL		SVOJSTVO	SIMBOL	JEDINICA	P-1 - JAŽA
metoda momenata s Chatwinovom metodom		srednje vrijeme prolaska trasera	t_0	h	16,88
		efektivna brzina	v	cm/s	4,36
		long. Disperzija	D_L	m^2/h	30863,16
		disperzivnost	α	m	196,76
		pecletov broj	Pe	-	13,46
CDE		srednje vrijeme prolaska trasera	t_0	h	8,03
		efektivna brzina	v	cm/s	9,16
		long. Disperzija	D_L	m^2/h	12000,00
		disperzivnost	α	m	36,39
		pecletov broj	Pe	-	72,74
SFD		srednje vrijeme prolaska trasera	t_0	h	8,27
		efektivna brzina	v	cm/s	8,89
		long. Disperzija	D_L	m^2/h	20971,57
		disperzivnost	α	m	65,50
		pecletov broj	Pe	-	40,42
		difuzija u matriks	a	$h^{-0.5}$	0,00308
MDM - SFD	PIK 1	srednje vrijeme prolaska trasera	t_0	h	8,27
		efektivna brzina	v	cm/s	8,89
		long. Disperzija	D_L	m^2/h	20971,57
		disperzivnost	α	m	65,50
		pecletov broj	Pe	-	40,42
		difuzija u matriks	a	$h^{-0.5}$	0,00308
	PIK 2	srednje vrijeme prolaska trasera	t_0	h	214,64
		efektivna brzina	v	cm/s	0,34
		long. Disperzija	D_L	m^2/h	79410,76
		disperzivnost	α	m	6438,15
		pecletov broj	Pe	-	0,41
		difuzija u matriks	a	$h^{-0.5}$	0,00750
	PIK 3	srednje vrijeme prolaska trasera	t_0	h	291,20
		efektivna brzina	v	cm/s	0,25
		long. Disperzija	D_L	m^2/h	16,01
		disperzivnost	α	m	1,76
		pecletov broj	Pe	-	1503,24
		difuzija u matriks	a	$h^{-0.5}$	0,00153
	PIK 4	srednje vrijeme prolaska trasera	t_0	h	391,70
		efektivna brzina	v	cm/s	0,19
		long. Disperzija	D_L	m^2/h	2,82
		disperzivnost	α	m	0,42
		pecletov broj	Pe	-	6344,67
		difuzija u matriks	a	$h^{-0.5}$	0,00261
2RNE*		srednje vrijeme prolaska trasera	t_0	h	20,37
		efektivna brzina	v	cm/s	3,61
		long. Disperzija	D_L	m^2/h	2881,00
		disperzivnost	α	m	22,16
		pecletov broj	Pe	-	119,46
		koeficijent udjela mobilne i nemobilne zone	β	-	0,38
		koeficijent prijenosa mase	ω	-	1,16

* - modelirana ulazna masa trasera

7.4.9.2.1 Metoda momenata s Chatwinovom metodom

Metodom momenata je obrađen kompletni prvi pik krivulje s repom, ali bez naknadna dva pika uzrokovana novim vodnim valovima.

Srednje vrijeme prolaska uranina je procijenjeno na 16,88 sati što daje srednju efektivnu brzinu od 4,36 cm/s. Longitudinalna disperzija je Chatwinovom metodom procijenjena na 30863,16 m²/h. Preračunato u disperzivnost dobivamo 196,76 m tj. Pecletov broj 13,46 (Slika 7.60).




Slika 7.60. Izračun Chatwinovog parametra za trasiranje uraninom izvedeno u listopadu 2012. godine

Na temelju srednjeg vremena prolaska trasera, napravljena je procjena volumena kanala koji sudjeluju u toku. Volumen iznosi 36111 m³, a pod pretpostavkom cilindričnog kanala, njegov polumjer iznosi 2,01 metar.

7.4.9.2.2 Equilibrium CDE – ravnotežni konvekcijsko-disperzijski model

Prilikom modeliranja CDE modelom u obzir je uzet samo prvi dio krivulje s glavnim pikom (Slika 7.61).

Srednje vrijeme prema CDE modelu je 8,03 sati uz srednju efektivnu brzinu prolaska trasa od 9,16 cm/s. Longitudinalna disperzija je procijenjena na 12000 m²/h što daje disperzivnost od 36,39 m i Pecletov broj 72,74.




Slika 7.61. Rezultati CDE modela za trasiranje uraninom izvedeno u listopadu 2012. godine

7.4.9.2.3 SFDM i MDM – jednopukotinski model disperzije i multidisperzijski model

Rezultati SFDM modela se poklapaju s prvom krivuljom MDM modela te će biti prikazani zajedno (Slika 7.62).

Srednje vrijeme prve krivulje je procijenjeno na 8,27 sata što daje srednju brzinu od 8,89 cm/s. Iznos longitudinalne disperzije je 20971,57 m²/h iz čega slijedi da je iznos disperzivnosti 65,5 m, a Pecletov broj 40,42. Difuzija u matriks iznosi 0,00308 h^{-0,5}.



Slika 7.62. Rezultati SFDM i MDM modela za trasiranje uraninom izvedeno u listopadu 2012. godine


Druga simulirana krivulja MDM modela ima srednje vrijeme prolaska traseira od 214,64 sati, što daje brzinu od 0,34 cm/s. Longitudinalna disperzija je 79410,76 m²/h, dok je disperzivnost 6438,15 m i Pecletov broj 0,41. Difuzija u matriks je procijenjena na 0,0075 h^{-0,5}.

Treća krivulja simulira drugi pik opažane krivulje i ima srednje vrijeme 291,2 sata i brzinu 0,25 cm/s. Longitudinalna disperzija je 16,01 m²/h, disperzivnost 1,76 m te Pecletov broj 1503,24. Difuzija u matriks je 0,00153 h^{-0,5}.

Četvrta i zadnja krivulja simulira zadnji pik na opažanoj krivulji koncentracije. Njeno srednje vrijeme je 391,7 sati ili preračunato u brzinu 0,19 cm/s. Longitudinalna disperzija je 2,82 m²/h iz čega se može zaključiti da je disperzivnost 0,42 m i Pecletov broj 6344,67. Difuzija u matriks je 0,00261 h^{-0,5}.

7.4.9.2.4 2RNE – neravnotežni dvo-zonski model

Prilikom primjene 2RNE modela je bilo potrebno u modelirane parametre staviti i masu trasera. U skladu s time, ulazna masa uranina je 220,02 g umjesto 100 g. U obzir je uzet samo prvi dio krivulje, bez zadnja dva pika. Srednje vrijeme prolaska uranina procijenjeno je na 20,37 sati. Preračunato u brzinu dobivamo 3,61 cm/s (Slika 7.63). Longitudinalna disperzija iznosi $2881 \text{ m}^2/\text{h}$ što daje disperzivnost od 22,16 m i Pecletov broj u vrijednosti od 119,46.




Slika 7.63. Rezultati 2RNE modela za trasiranje uraninom izvedeno u listopadu 2012. godine

Koeficijent udjela mobilne i nemobilne zone iznosi 0,38, dok je koeficijent prijenosa mase 1,16.

7.4.10 Usporedba protoka na ponorima P-1 i P-2 s izvorom Jaža

Iako je mjerenje visokih voda na ponorima nemoguće ili teško izvedivo, za većinu vodostaja koji su vladali u vrijeme trasiranja su izrađene protočne krivulje. Obzirom

da su tijekom vremena opažanja uvjeti na ponorima i izvorima bili vrlo varijabilni, nije moguće napraviti jednostavnu usporedbu količina. Radi toga je najjednostavnije usporediti zbrojene hidrograme ponora s hidrogramom izvora Jaža u vremenima trajanja trasiranja (Slika 7.64).



Slika 7.64. Zbirni hidrogrami protoka na ponorima P-1 i P-2 i protoka na izvoru Jaža u vrijeme izvođenja trasiranja.

Iz priloženih hidrograma se može primijetiti da je količina vode na Jaži veća ili približno jednaka ukupnom protoku s oba ponora. Imajući u vidu dobivene pronose, možemo ustanoviti da po tipu kanala (poglavlje 7.1.4, str. 82), sustav ponora i izvora Jaža pripadaju tipu II. Nizak pronos tijekom trasiranja ponora P-1 u lipnju 2012. godine ostavlja sumnju da je moguć i tip IV ili tip VI.

8 RASPRAVA

U sklopu istraživanja krških vodonosnika izvora Jaže i Obrva napravljeno je ukupno devet trasiranja na tri različite lokacije. Rezultati tih trasiranja obrađeni su primjenom pet modela (metoda momenata s Chatwinovom metodom, CDE, SFDM, MDM, 2RNE). Pri tome su određeni parametri toka i transporta koji su pokazali veliki raspon vrijednosti ovisno o primijenjenom modelu, a posebno obzirom na hidrološke uvjete koji su vladali tijekom pojedinog trasiranja.

8.1.1 Analiza primijenjenih modela

Cilj ovog rada nije ocjenjivanje pojedinih modela, ali obzirom na broj analiziranih trasiranja, može se dobiti uvid u njihovu primjenjivost u određenim uvjetima. Svaki model je baziran na drugom konceptu, pa radi toga i vrijednosti parametara variraju ovisno o primijenjenom modelu. Svi modeli nisu primjenjivi kod svih trasiranja, tako je trasiranje Jamine pod Piskom analizirano samo s dva modela zbog specifične krivulje koncentracije. O tom trasiranju će biti više riječi u poglavlju 8.1.4.

Kod analitičkih modela na prvi pogled je vidljiva uspješnost preklapanja modelirane i opažane krivulje koncentracije trasera. Iako njihovo preklapanje treba biti što bolje, sama uspješnost preklapanja ne garantira i točnost rezultirajućih parametara. Dobar primjer izvrsnog preklapanja krivulje je modeliranje trasiranja ponora P-1 izvedenog u lipnju 2012. godine (poglavlje 7.4.7, str. 136). Dobro preklapanje krivulja postignuto je svim analitičkim modelima, ali posebno zanimljivi su CDE i 2RNE modeli. Kod oba modela preklapanje je izvrsno (Slika 7.49, str. 141 i Slika 7.51, str. 143), ali iznos longitudinalne disperzije se značajno razlikuje o čemu će u nastavku biti više rečeno. Treba napomenuti da CDE model možemo smatrati samo pojednostavljenim 2RNE modelom u slučaju kad nema utjecaja nemobilne zone fluida. Dakle, 2RNE modelom je moguće doći do istog rezultata kao i CDE modelom. U oba slučaja preklapanje krivulja će biti gotovo identično i po tom kriteriju neće biti moguće odabrati prihvatljivo rješenje.


Analizirajući rezultate trasiranja, vidljivo je odstupanje vrijednosti modeliranih parametara ovisno o modelu. Iako ima izuzetaka, mogu se odrediti i neka generalna pravila relativne vrijednosti određenog parametra i modela.

Iako preklapanje krivulja nije dovoljan kriterij za prihvaćanje rezultata modela, svakako treba biti postignuto u što većoj mjeri. Većina krivulja koncentracije trasera dobivenih trasiranjem u kršu ima više ili manje izražene repove. Isti zaključak se može dobiti i za trasiranja izvršena u sklopu ovih istraživanja. Jedino trasiranje gdje je rep slabo izražen je trasiranje ponora P-1 u lipnju 2012. godine. Kod svih ostalih trasiranja javlja se više ili manje izražen rep i to je glavni razlog za najbolje preklapanje krivulja MDM i 2RNE modelima. Samo ta dva modela mogu interpretirati repove. U slučaju MDM modela to se postiže preklapanjem nekoliko krivulja koje predstavljaju zasebne putanje sa zasebnim parametrima, dok 2RNE model uvodi mobilnu i nemobilnu zonu između kojih postoji interakcija koja uzrokuje repove krivulja. SFDM model pokušava objasniti repove krivulja difuzijom trasera u matriks i kasnijim otpuštanjem. Taj model je prvenstveno namijenjen pukotinskim vodonosnicima. U slučaju vodonosnika izvora Jaže, obzirom na velike brzine toka, može se zaključiti da se radi o dobro razvijenom krškom vodonosniku s razvijenim kanalima. U tim uvjetima SFDM model nije mogao samostalno simulirati kompletne opažane krivulje koncentracije.

MDM modelom se opažane krivulje mogu dobro simulirati kombiniranjem dvije ili više krivulja koncentracije. Parametri krivulja dobivenih MDM modelom teško se mogu uspoređivati s ostalim modelima. Najveća prednost MDM modela je mogućnost modeliranja krivulja s više pikova. Radi toga je trasiranje Jamine pod Piskom (Slika 7.43, str. 132) obrađeno jedino metodom momenata i MDM modelom.

Iako su MDM i 2RNE modeli bili najuspješniji u simuliranju opažanih krivulja koncentracije, ne treba podcijeniti ostale modele. Statistička metoda momenata s Chatwinovom metodom za disperziju je često polazna točka prilikom analize rezultata trasiranja. Ukoliko imamo kvalitetne ulazne podatke, prvenstveno krivulju koncentracije trasera, pomoću te metode možemo dobiti dobre polazne parametre za ostale modele. Metoda je relativno jednostavna i nudi jedinstveno rješenje. Chatwinova metoda za procjenu disperzije predstavlja prosjek utjecaja mobilnog

fluida, prostorno varirajućeg toka i transporta te mobilnog fluida (Field & Pinsky, 2000). U slučaju da sustav djeluje po Fickovom zakonu, disperzija dobivena Chatwinovom metodom uglavnom će biti podcijenjena (Field, 2002). Slika 8.1 prikazuje iznos longitudinalne disperzije za sva trasiranja ponora P-1 i P-2. Primjećuje se da je iznos disperzije dobiven Chatwinovom metodom manji od iznosa dobivenog CDE metodom kod svega tri trasiranja (P-1 u svibnju 2009. godine, P-2 u srpnju 2011. godine, P-1 u lipnju 2012. godine). To su ujedno jedina trasiranja kod kojih glavni pik krivulje koncentracije boje nije podudaran s nailaskom vodnog vala na izvoru. Logična je pretpostavka da je radi toga Fickov zakon imao veći utjecaj (veći utjecaj molekularne difuzije nego kod ostalih trasiranja) te su stoga iznosi disperzije dobiveni Chatwinovim modelom manji od CDE modela.




Slika 8.1. Usporedba longitudinalne disperzije u ovisnosti o primijenjenom modelu. Nisu prikazani rezultati trasiranja Jamine pod Piskom niti rezultati MDM modela. Trasiranja su razvrstana po mjestu i vremenu ubacivanja trasera. Obratiti pažnju na logaritamsko mjerilo ordinate (disperzije).

CDE model je vrlo često primjenjivan model. Njegov najveći nedostatak je simuliranje isključivo transporta pod utjecajem Fickovog zakona. On ne može objasniti repove krivulja koji su primijećeni kod većine trasiranja provedenih u sklopu ovog rada.

Usprkos toga ne treba ga odbaciti jer je njegova jednostavnost zaslužna za jedinstvenost rješenja.


2RNE model je najsloženiji od primijenjenih modela. Pod pretpostavkom konzervativnog traseira, za modeliranje je ostalo čak četiri parametra (srednja efektivna brzina, disperzija, koeficijent udjela mobilne i nemobilne zone i koeficijent prijenosa mase). Koeficijenti udjela mobilne i nemobilne zone i prijenosa mase definiraju utjecaj nemobilne zone koji uzrokuju repove krivulja (van Genuchten, 1981) (Slika 8.2).




Slika 8.2. Konceptualni model geometrije i tečenja kroz krški kanal (Geyer et al., 2007)

Utjecaj nepravilnosti krških kanala na disperziju i retardaciju krivulje koncentracije traseira je testirao Hauns (2001). Testiranje je radio pomoću numeričkog 3D modela dinamike fluida. Zahtjevnost algoritma je sprječavala vršenje simulacija na duljinama većim od približno jednog metra. Pojednostavljivanjem numeričkog modela eksperiment je izvršen i na duljinama od otprilike deset metara, a na poslijetku izvršena su i stvarna trasiranja u istraženom speleološkom objektu duljine preko 1000 metara.

Rezultati eksperimenta su pokazali jasan utjecaj nepravilnosti kanala (Slika 8.3) na povećanje disperzije i retardacije krivulje (Slika 8.4). Uzrok je povratni tok i vrtloženja koja nastaju zbog nepravilnosti kanala.



Slika 8.3. Geometrija kanala sa strujnicama tečenja vode u bazenima i brzacima: (A) kanal konstantne širine; (B) kanal nepravilne širine; (C) trapezoidni bazen; (D) bazen s jednom preprekom; (E) „laboratorijski“ bazen; (F) bazen s dijagonalno nasuprotnim ulazom/izlazom; (G) bazen s tri prepreke; (H) hidraulički skok ili brzac (Hauns 2001).



Slika 8.4. Disperzija i retardacija uzrokovana različitom geometrijom kanala sa Slika 8.3. Veći vrtlozi uzrokuju veću retardaciju (Hauns 2001).


Navedena istraživanja i iskustva iz speleoloških istraživanja idu u prilog definiranja mobilne i nemobilne zone prilikom modeliranja tečenja kroz krške kanale.

Problemi kod 2RNE modela se javljaju prilikom kalibriranja modelirane krivulje koncentracije na opažanu. Postoje više kombinacija parametara koje daju sličnu krivulju koncentracije. Radi toga je potreban oprez prilikom tumačenja rezultata.

Longitudinalna disperzija je kod 2RNE modela generalno najmanja između primijenjenih modela (Slika 8.1). Razlog tome su dodatni parametri koji definiraju utjecaj nemobilne zone koji u ostalim modelima ne postoje. Djelovanje nemobilne zone uzrokuje disperziju i preklapa se s djelovanjem koeficijenta disperzije. To je najčešći uzrok višeznačnosti rješenja.

Kod SFDM modela također postoji parametar a koji definira difuziju u matriks i čije djelovanje djelomično uzrokuje disperziju. Usprkos tome, iako su uočljive nešto niže vrijednosti longitudinalne disperzije kod SFDM modela, razlika je puno manja jer je utjecaj matriksa bio mali.

Slika 8.5 prikazuje vrijednosti srednjeg vremena prolaska trasera kroz vodonosnik.



Slika 8.5. Usporedba srednjeg vremena prolaska trasera u ovisnosti o primijenjenom modelu. Nisu prikazani rezultati trasiranja Jamine pod Piskom niti rezultati MDM modela. Trasiranja su razvrstana po mjestu i vremenu ubacivanja trasera.




Vrijednosti vremena su slične među modelima, ali može se zapaziti generalna tendencija veće vrijednosti vremena kod metode momenata i 2RNE modela. CDE i SFDM modeli ne uspijevaju simulirati repove krivulja, te je posljedično vrijeme prolaska trasera kraće. Jedini izuzetak od tog pravila je trasiranje ponora P-2 u srpnju 2011. godine. U tom slučaju je metodom momenata dobiveno najkraće srednje vrijeme prolaska trasera, iako je uobičajeno da se tom metodom, uz 2RNE model, dobivaju najduža vremena. Uzrok tome je vjerojatno veliki vodni val koji se poklopio s nadolaskom trasera, ali je brzo pao, prije dolaska glavine trasera. U tom slučaju je statistička metoda momenata uzela to u obzir i „težište“ krivulje postavila ranije. 2RNE model je imao najdulje vrijeme što je kod njega uobičajeno obzirom da modelirane krivulje imaju rep. Podudaranje metode momenata i SFDM modela je vjerojatno slučajnost. Kad bi u obzir uzeli i drugu krivulju MDM modela vrijeme bi bilo bliže 2RNE modelu.

Prilikom analiziranja rezultata modela treba obratiti pažnju na dinamiku istjecanja vode na izvoru. Većina krških izvora ima vrlo brzu i čestu promjenu količine istjecanja

vode. Ovdje prikazani izvori Jaža i Obrv nisu iznimka. Rješenja analitičkih modela su predviđena za jednoliki protok. Čak i bez obzira na analitička rješenja modela, prilikom mijenjanja protoka sigurno dolazi do znatne promjene uvjeta tečenja u kanalima (vadozni, freatski) koji ne mogu biti adekvatno aproksimirani modelima. Usprkos toga, analitički modeli korišteni u ovom radu su već korišteni i u hidrološki vrlo promjenjivim uvjetima (Göppert & Goldscheider, 2008).

Werner et al. (1997) su testirali rezultate trasiranja tijekom dinamičkih hidroloških uvjeta statičkim analitičkim modelom i dinamičkim numeričkim modelom. Rezultati se mogu vidjeti na SliciSlika 8.6. Može se primijetiti da vrijednosti srednjeg vremena prolaska trasera i disperzivnosti ovise o promjeni protoka. Pri tome u svim slučajevima promjene protoka dolazi do podcjenjivanja disperzivnosti kod analitičkih modela, dok srednje vrijeme prolaska trasera ovisi o odnosu promjene protoka naspram koncentracije trasera.

Većina trasiranja izvedena u sklopu ovog rada ima nejednolike uvjete istjecanja. Samo su trasiranja ponora P-1 u svibnju 2009. godine i lipnju 2012. godine, te Jamine pod Piskom u lipnju 2012. godine izvedena u približno jednolikom režimu istjecanja vode na izvoru. Tijekom svih ostalih trasiranja je došlo do naglog povećanja protoka u nekom dijelu istjecanja trasera, te je vjerojatno da su vrijednosti disperzivnosti kod njih podcijenjene. U slučaju trasiranja ponora P-2 u srpnju 2011. godine i listopadu 2012. godine, te ponora P-1 u listopadu 2012. godine je moguće da je i srednje vrijeme prolaska trasera podcijenjeno.

Protok	Primjer	Srednje vrijeme t_0	Disperzivnost α_L
Kontinuirano povećavan protok		-	+
Konstantan protok s ekstremnim pikom		=	+
Nepravilan protok		+	+

+ znači da je vrijednost kod nejednolikog toka veća nego kod jednolikog
 - znači da je vrijednost kod nejednolikog toka manja nego kod jednolikog

Slika 8.6. Utjecaj dinamike toka tijekom trasiranja na rezultate modela (modificirano prema Werner et al. 1997)


Promjene dinamike tečenja tijekom trasiranja su vjerojatni razlog potrebe za modeliranjem mase trasera u nekim slučajevima CDE i 2RNE modela. Iznimka je trasiranje ponora P-1 izvedeno u lipnju 2012. godine. Mogući razlog za potrebu modeliranja mase u tom slučaju je prije spomenuta greška u mjerenju protoka tj. gubitak dijela protoka u aluviju potoka Jaševnica. Radi toga nije izmjerena prava masa trasera, te se posljedično u modelu nije mogla postići odgovarajuća bilanca mase ubačenog i detektiranog trasera.

8.1.2 Pronos i bilanca mase

Smisao kvantitativnog trasiranja je izrada bilance mase ubačenog i detektiranog traseru na mjestima opažanja. Količina detektiranog traseru se izražava pomoću pronosa tj. postotka ubačene količine traseru detektiranog na pojedinoj lokaciji opažanja. U slučaju svih trasiranja izvedenih u sklopu ovog istraživanja, traser je zabilježen isključivo na jednoj lokaciji po trasiranju (izvori Jaža ili Obrv).

Maksimalni teoretski pronos tijekom jednog trasiranja može biti 100%. To bi značilo da je sav ubačeni traser detektiran na mjestima opažanja. U praksi pronosi obično ne prelaze 90% (Field & Nash, 1997).

Slika 8.7 prikazuje pronose svih trasiranja izvršenih u sklopu ovog rada.



Slika 8.7. Iznosi pronosa za sva trasiranja napravljena u sklopu ovog istraživanja. Trasiranja su razvrstana po mjestu i vremenu ubacivanja traseru.

Može se primijetiti da većina trasiranja ima vrlo visok pronos. Kod dva izvršena trasiranja on čak prelazi teoretski maksimalnih 100%. Takav rezultat je moguć isključivo radi pogreške koja može biti posljedica različitih uzroka. Moguća je

promjena pozadinske koncentracije trasera, greška u mjerenju koncentracije, greška u mjerenju protoka, dolazak trasera od nekog prijašnjeg trasiranja, neadekvatna gustoća uzorkovanja itd.

Kod trasiranja ponora P-1 u srpnju 2011. i listopadu 2012. godine, zabilježeni su pronosi od 104% uranina. Pozadinska koncentracija uranina je vrlo stabilna, pogotovo na tom području jer nema onečišćivača koji mogu ispustiti supstance koje se preklapaju s valnim duljinama uranina. Iako je rađeno više uzastopnih trasiranja, nije vjerojatno da je došlo do duljeg zadržavanja uranina u vodonosniku i kasnijeg otpuštanja. To pogotovo vrijedi za trasiranje u srpnju 2011. godine, jer je prethodno trasiranje bilo u svibnju 2009. i imalo je visok pronos. Greške u mjerenju koncentracije su isto teško moguća jer su mjerenja vršena terenskim fluorometrima i periodično provjeravana u laboratoriju pomoću spektrofluorometra. Gustoća mjerenja je bila vrlo velika tako da je i ta mogućnost isključena.

Najvjerojatniji uzrok greške u pronosu je mjerenje protoka. Sama greška mjerenja je otprilike 10%. Već takva greška može objasniti pronose od 104%. Obzirom da su mjerenja protoka bila korištena za izradu protočne krivulje za neuređeno korito potoka, vrlo je vjerojatno da i tu ima određena doza nepravilnosti. To je pogotovo vjerojatno za trasiranje u listopadu 2012. godine kada su izmjereni vrlo visoki protoci. Obzirom na kratko trajanje visokih voda, u tim uvjetima redovito ima najmanje mjerenja, pa je i pouzdanost protočne krivulje najmanja.


Kod većine trasiranja pronosi su vrlo visoki, što sugerira da je veza trasiranih ponora i izvora izravna. To potkrepljuje i činjenica da traser nije zabilježen niti na jednom drugom mjestu opažanja. Ipak, na tri trasiranja pronos je bio manji od očekivanog (trasiranja ponora P-2 u srpnju 2011., Jamine pod Piskom i ponora P-1 u lipnju 2012.) iako traser niti u tim slučajevima nije zabilježen nigdje drugdje.

Zajednička osobina ova tri trasiranja je dugačak period istjecanja trasera u režimu niskih voda na izvoru Jaža, odnosno Obrv. Ponori P-1 i P-2 su u drugim trasiranjima imali izravnu vezu s izvorom Jaža. Iako nije isključeno da u uvjetima niskih voda smjer tečenja bude djelomično promijenjen, malo je vjerojatno da traser ne bi bio detektiran na drugim mjestima opažanja. Moguće je da je uslijed malih brzina tečenja

došlo do razrjeđenja trasera i laganog istjecanja ispod razine detekcije. Druga mogućnost i u ovom slučaju može biti vezana uz protok. Uz već navedenu grešku kod mjerenja protoka i protočne krivulje, moguće je da dio vode izvora Jaža i Obrv izbija nizvodnije u koritu i na taj način prolazi nezapaženo. U slučaju srednjih i visokih voda, ta količina je zanemariva, ali u slučaju niskih voda mala količina takve vode može drastično smanjiti pronos. Najvjerojatnije se radi o kombinaciji gore spomenutih faktora.


8.1.3 Utjecaj hidroloških uvjeta na parametre tečenja i transporta

Izvršeno je sveukupno devet trasiranja, na tri lokacije. Ponor P-1 je trasiran pet puta, ponor P-2 tri puta i Jamina pod Piskom jednom. Krivulje koncentracije trasera značajno variraju izgledom i trajanjem, posebno odudara trasiranje Jamine pod Piskom (Slika 8.8).



Slika 8.8. Normalizirane krivulje koncentracije trasera za sva izvedena trasiranja. Razvrstana su po mjestu ubacivanja trasera i vremenu izvođenja.

Trasiranja su izvedena u različitim hidrološkim uvjetima (Slika 8.9).




Slika 8.9. Protoci na izvorima na kojima je zabilježena pojava trasera u vremenu trajanja istjecanja trasera. Brojem je istaknuti prosječni protok.

Tipično krško funkcioniranje izvora Jaže i Obrva je vidljivo već iz samih protoka za vrijeme trajanja pojedinačnih trasiranja. Za vrijeme gotovo svih trasiranja je došlo do znatne razlike u količini vode koja istječe na izvorima. Izuzetak su samo trasiranja ponora P-1 izvedena u svibnju 2009. i lipnju 2012. godine.

Zbog te tipične varijabilnosti protoka, nije jednostavno razgraničiti trasiranja po hidrološkim uvjetima. Tipični uvjeti niskih voda su vladali za vrijeme trasiranja ponora P-1 u lipnju 2012. godine. Za trasiranja ponora P-1 i P-2 u srpnju 2011. i Jamine pod Piskom u lipnju 2012. godine možemo reći da su započeta u uvjetima niskih voda, ali je u nekom trenutku došlo do kratkotrajnog, ali naglog porasta protoka koji je djelomično poremetio te uvjete. Trasiranja ponora P-1 i P-2 u veljači 2012. godine po protoku spadaju u uvjete srednjih voda, ali u vrlo nejednolikom režimu istjecanja jer se ubacivanje trasera pokušalo napraviti u toku nadolazećeg vodnog vala. Puno mirniji režim istjecanja na izvoru Jaža u režimu srednjih voda je bio prilikom trasiranja ponora P-1 u svibnju 2009. godine. Posljednja dva trasiranja ponora P-1 i P-2 izvedena u listopadu 2012. godine po količini protoka na izvoru Jaža svakako


spadaju u uvjete visokih voda. Ipak, treba naglasiti da to nisu bili pravi uvjeti visokih voda jer podzemlje nije bilo prethodno saturirano vodom. Traseri su ubačeni prilikom jakih kiša koje su uzrokovale veliki vodni val unutar perioda srednjih voda. Obzirom na relativno mali volumen vodonosnog sustava, može se smatrati da su za vrijeme samog trasiranja vladali uvjeti visokih voda. To dokazuju i rezultati s vrlo visokim brzinama, čak i za standarde našeg krša (Slika 8.10).



Slika 8.10. Brzine prvog nailaska traseri za sva trasiranja. Brzine su izračunate koristeći pravocrtnu udaljenost mjesta ubacivanja i detekcije traseri sukladno dosadašnjoj praksi u našim krajevima.

Najniža brzina prvog nailaska zabilježena je prilikom trasiranja Jamine pod Piskom u dolomitnom vodonosniku. U smislu hidroloških uvjeta, to trasiranje se može usporediti s trasiranjem ponora P-1 koje je napravljeno samo dva dana kasnije i nalazi se u vapnenačkim brečama. U tadašnjim uvjetima istjecanja, to nije predstavljalo bitnu razliku. Najveća razlika radi koje ne možemo izravno uspoređivati rezultate ta dva trasiranja je tip mjesta ubacivanja traseri. U slučaju ponora P-1 radi se o aktivnom ponoru zahvaljujući kojem traser (naftionat) ima brz pristup saturiranoj zoni. U drugom slučaju traser (uranin) ubačen je u suhu jamu te je ispiran dopremljenom vodom. Imajući to u vidu, kao i obično manju propusnost dolomitnih

naslaga naspram vapnenačkih, mogla bi se očekivati i veća razlika u brzinama. Treba napomenuti da brzina prvog nailaska nije najbolja opcija za tumačenje fizikalnih zakonitosti tečenja. Ono ima malo teoretskog značenja i najviše ovisi o granici detekcije trasera i gustoći opažanja. Značajna je jedino za studije o zagađivanju jer daje indikaciju koliko vremena će proći do dolaska zagađivala na izvor (Field, 2002). Puno više fizikalnog značenja ima srednja efektivna brzina prolaska trasera koja pokazuje brzinu centra mase trasera, te time zapravo bolje opisuje kretanje trasera. Razlike za ta dva trasiranja u toj brzini su puno očitije nego kod brzina prvog nailaska, kao što je i očekivano za trasiranja u tako različitim medijima (Slika 8.11).




Slika 8.11. Srednja efektivna brzina trasera za sva trasiranja. Brzine su izračunate koristeći modificiranu udaljenost mjesta ubacivanja i detekcije trasera te nisu izravno usporediva s prikazanim brzinama prvog nailaska. Brzine su napisane samo za metodu momenata.

Također su vidljive manje međusobne razlike kod simultanih trasiranja nego u slučaju brzina prvog nailaska (osobito za zadnje trasiranje u listopadu 2012. godine).

Kod obje brzine vrijedi zakonitost da je brzina veća kod visokih voda nego kod niskih voda. Ovdje se može vidjeti da je razlika u srednjoj efektivnoj brzini u čitavom redu veličine, a za brzinu prvog nailaska razlika je čak u dva reda veličine.


Trasiranja ponora P-1 i P-2 u srpnju 2011., te ponora P-1 u lipnju 2012. godine su indikativna za razumijevanje utjecaja vodnih valova na karakteristike toka. Sva tri trasiranja su započeta u uvjetima malih voda, ali kod prva dva je došlo do naglog porasta protoka uslijed kiše. Može se primijetiti da je utjecaj na srednju efektivnu brzinu vrlo mali, ali ipak se primjećuje njen mali porast zbog nadolaska vodnog vala. Puno drastičnija promjena se odražava na disperzivnost (Slika 8.12).



Slika 8.12. Disperzivnost za sva trasiranja.

Iznos disperzivnosti je drastično različit za trasiranja u srpnju 2011. godine od iznosa disperzivnosti za ostala trasiranja iako se radi o simultanom trasiranju. Razlike zbog različitih svojstava kanala između ponora P-1 i P-2 vjerojatno nisu uzrok jer pri ostalim simultanim trasiranjima nema tako očite razlike u parametrima. Najlogičniji uzrok razlike je utjecaj vodnog vala. U slučaju ponora P-1 vodni val se gotovo savršeno preklopio s nadolaskom trasera (Slika 7.19, str. 103) i posljedično drastično

smanjio disperziju. Istovremeno, Pecletov broj ukazuje na apsolutnu dominaciju advekcije u procesu transporta kakva nije zabilježena niti kod jednog preostalog trasiranja (Slika 8.13).




Slika 8.13. Pecletov broj za sva trasiranja. Obratiti pažnju na logaritamsko mjerilo ordinate (Pecletovog broja).

Kod disperzivnosti trasiranja ponora P-2 vidi se suprotan učinak, tj. povećanje disperzivnosti naspram slučaju iz lipnja kada je tok bio jednolik cijelo vrijeme. U tom slučaju vodni val je došao na izvor prije nailaska glavnine trasera (Slika 7.25, str. 110). Uzrok je vjerojatno dulji put od ponora P-2 do izvora.

Sudeći po rezultatima izvršenih trasiranja, disperzivnost je prilikom jednolikog protoka najmanja kod srednjih voda, kod niskih voda raste, dok kod visokih voda ima najveće vrijednosti. Usprkos tome, krivulje koncentracije trasera u uvjetima visokih voda nisu toliko široke zbog vrlo velikih brzina tj. kratkog trajanja djelovanja disperzije. Preklapanje vodnih valova s nailaskom trasera smanjuje disperziju. Taj efekt se može primijetiti na već spomenutom trasiranju ponora P-1 u srpnju 2011., ali i na trasiranjima u veljači 2012. godine. Trasiranje ponora P-2 u srpnju 2011. godine

indicira da prolaskom vodnog vala disperzija raste, kao i ukupno trajanje istjecanja trasera.

Procjena volumena kanala koji sudjeluju u toku je napravljena korištenjem jednadžbe (7-24) s time da je korišteno srednje efektivno vrijeme dobiveno pomoću metode momenata (osim trasiranja Jamine pod Piskom gdje je dodatno korišteno i vrijeme dobiveno s prvim pikom MDM modela) (Slika 8.14).




Slika 8.14. Procjena volumena kanala koji sudjeluju u toku za pojedinačna trasiranja. Procjena je napravljena na temelju srednjeg efektivnog vremena dobivenog metodom momenata. Iznimka je trasiranje Jamine pod Piskom gdje je označen i volumen dobiven na temelju prvog pika MDM modela (manji volumen).

Procijenjeni volumeni tj. količina vode koja je u sustavu, jasno korelira s hidrološkim uvjetima. Jasna je razlika u volumenima sustava ponora P-1 i P-2 prilikom simultanih trasiranja. Očekivano veći volumen je u sustavu ponora P-2 obzirom da je udaljeniji od izvora Jaža. Volumeni kanala ne pokazuju korelaciju s izračunatim pronosima (Slika 8.7, str 170). Trasiranje ponora P-1 u lipnju 2012. godine ima najmanji volumen, ali i najmanji pronos od svih izvedenih trasiranja. Trasiranje Jamine pod Piskom izvedeno dva dana ranije ima neznatno veći pronos, ali najveći volumen. Obzirom da je traser u tom slučaju došao na izvor Obrv, očigledno je da pripada

drugom sustavu te se ne može izravno uspoređivati sa sustavom izvora Jaža. Osim toga, ukoliko se kao mjerodavan uzme volumen izračunat samo na temelju prve krivulje MDM modela, volumen je $21\,444\text{ m}^3$ što je slično volumenima za Jažu. Jedino preostalo trasiranje s niskim pronosom je trasiranje ponora P-2 iz srpnja 2011. godine s 55,15%. Usprkos manjem pronosu od simultano izvršenog trasiranja ponora P-1, trend u razlici volumena je zadržan.

8.1.4 Trasiranje Jamine pod Piskom

Trasiranje Jamine pod Piskom je jedino trasiranje koje je dalo rezultate na izvor Obrv i to s vrlo specifičnom krivuljom koncentracije trasera (Slika 8.15). Obzirom na hidrogeološku kartu, može se zaključiti da je tečenje bilo isključivo kroz gornjotrijaske dolomite.



Slika 8.15. Krivulja koncentracije trasera (uranina), protoka na izvoru Obrv i količina dnevnih oborina zabilježenih na kišomjeru u selu Gornji Oštrc.


Od svih provedenih trasiranja u sklopu ovog rada, u ovom slučaju trajanje istjecanja je bilo daleko najdugotrajnije. Jedan od bitnih čimbenika za takav rezultat sigurno je

mjesto ubacivanja trasera. Jedino u ovom slučaju je to bila jama bez ikakvog toka vode. Obzirom da na slivnom području Obrva nema aktivnih ponora, moralo se pristupiti trasiranju takvog objekta. Prilikom obilaska terena, izabrana je upravo ova lokacija usprkos većem gradijentu prema izvoru Studena i radi toga velikoj mogućnosti da traser ne dođe na Obrv. Slika 8.16 prikazuje kartu gradijenta reljefa koja prikazuje težnju smjera kretanja vode uvažavajući isključivo hipsometrijske odnose i horizontalnu udaljenost trasiranog objekta naspram ostatka terena. Jednadžba gradijenta reljefa je analogna jednadžbi hidrauličnog gradijenta:

$$J_{relj} = -\frac{dh_{relj}}{dl_{relj}} \quad (8-1)$$

Gdje je J_{relj} = gradijent reljefa (-), dh_{relj} = visinska razlika razine trasiranog objekta i točke na terenu (m), dl_{relj} = horizontalna udaljenost trasiranog objekta i točke na terenu (m).

Jednadžba (8-1) se računa za svaku točku terena, te se dobiva raster na kojem se lako mogu uočiti mjesta s većom vjerojatnosti dolaska trasera.




Slika 8.16. Karta gradijenta reljefa (gradijent izračunat pomoću visine terena i horizontalne udaljenosti) za Jaminu pod Piskom.

Višestruki pikovi na krivuljama koncentracije trasera nisu česta, ali niti posebno neuobičajena pojava. Obično su uzrokovani bifurkacijama toka ili dolaskom naknadnih vodnih valova (primjerice Slika 7.53 na str. 145 i Slika 7.59 na str. 153). Vrlo je rijetka pojava maksimalne koncentracije trasera u naknadnim pikovima, pogotovo bez utjecaja naknadnih vodnih valova. Prilikom trasiranja Jamine pod Piskom, značajnije količine kiše su pale tek prilikom i nakon istjecanja drugog pika. Prije nailaska drugog pika pala je mala kiša od svega 3,2 mm koja je vrlo teško mogla uzrokovati njegov dolazak na izvor. Utjecaj te kiše nije uzrokovao nikakav porast protoka na izvoru Obrv.

Jedno od mogućih objašnjenja je postojanje najmanje dvije putanje toka vode. Obzirom na rezultate MDM modela, mogu se pretpostaviti tri putanje (Slika 7.45, str. 135). Nelogičnost te hipoteze je pojava maksimalne koncentracije u najsporijem piku koji se na izvoru Obrv pojavio tek nakon otprilike 52 dana nakon ubacivanja trasera. Obzirom da je u zadnjem piku došla glavnina detektiranog trasera, on je trebao putovati glavnim kanalom. Istovremeno je njegova brzina bila najmanja što je u koliziji

s prethodnom tvrdnjom. Zbog toga se hipoteza o bifurkaciji na dva ili više kanala čini malo vjerojatnom.

Hipoteza koja se čini kao najvjerojatnije objašnjenje dobivene krivulje koncentracije uključuje sporedni prostor u kojem je uskladištena voda s traserom i njenu interakciju s kanalom veće propusnosti. Po toj teoriji voda s traserom je dospjela u prostor koji je u vezi s kanalom velike propusnosti. Njihova interakcija je uvjetovana manjim spojnim kanalom (ili pukotinskim sustavom) i razlikom potencijala u glavnom kanalu i prostoru s uskladištenom vodom. Dok je god voda u kanalu iznad neke kritične razine, traser iz rezervoara ne može prodrijeti u kanal u značajnijoj količini. Tek nakon što razina vode padne ispod kritične razine, voda s traserom iz rezervoara ulazi u kanal i teče prema izvoru (Slika 8.17). Prilikom ubacivanja trasera, u jamu je ubačeno otprilike 70 m³ vode. Već ta količina vode mogla je uzrokovati rast potencijala u rezervoaru dovoljan za prolazak dovoljne količine trasera za prvi zabilježeni pik na krivulji koncentracije. Drugi pik se dogodio nakon što je potencijal u kanalu pao ispod kritične razine. Zbog naknadnog porasta ukupne razine podzemne vode, uslijed kiša koje su pale tijekom izlaženja drugog pika, došlo je do prestanka pražnjenja rezervoara s traserom i posljedično njegovog izlaženja na izvoru. Imajući u vidu pronos od svega 33%, nije isključeno da će u sljedećim uvjetima niskih voda doći do ponovnog istjecanja trasera (uranina).



Slika 8.17. Moguće objašnjenje rezultata trasiranja Jamine pod Piskom. Različitim bojama su označeni potencijali u glavnom kanalu i spremniku s vodom i traserom, te smjer tečenja vode: crvena boja - vrijeme upuštanja 70 m³ vode s traserom; narančasta boja - nakon završetka upuštanja traseru; zelena boja – pad potencijala u glavnom kanalu uslijed dovoljno duge recesije.

8.1.5 Volumeni kanala

U sklopu istraživanja vodonosnika izvora Jaže i Obrva, različitim metodama su se procijenili volumeni određenih segmenata za određene hidrološke uvjete. Tijekom trasiranja su procijenjeni ukupni volumeni kanala koji su sudjelovali u tečenju. Analizom vodnih valova (*storm evenata*) pomoću prirodnog traseru (elektrolitičke vodljivosti) dobiveni su volumeni freatskih kanala neposredno prije nadolaska vodnog vala. Krivuljom recesije je dobivena procjena ukupne uskladištene količine vode koja će se gravitacijski izdrenirati iz vodonosnika.

Iako ti volumeni predstavljaju različite dijelove vodonosnika i prema tome nisu izravno usporedivi, njihovim preklapanjem dobivamo jasniji pogled na njihovu građu.

Najveći volumen kod oba vodonosnika (izvora Jaže i Obrva) pripada volumenu dobivenim pomoću koeficijenta recesije. U slučaju Jaže taj volumen je $86\,495\text{ m}^3$, dok je u slučaju Obrva volumen $50\,205\text{ m}^3$. Oba volumena su računata za recesiju koja započinje srednjim protokom za pripadajuće izvore, te predstavljaju konzervativnu procjenu. Ako te volumene usporedimo s ukupnim volumenima kanala dobivenim trasiranjima dobiti ćemo grubu procjenu volumena matriksa i pukotina manjih dimenzija koje ne sudjeluju u brzom toku (Slika 8.14, str. 178). Odmah se primjećuje da je kod oba vodonosnika taj volumen vrlo mali jer su volumeni kanala i ukupni volumen vodonosnika u istom redu veličine. To se može smatrati relativno rijetkim slučajem jer je u kršu uobičajeno da je uskladištenje u sitnim porama za jedan ili dva reda veličine veće od uskladištenja u velikim pukotinama i kanalima (Krešić, 1997; Grasso & Jeannin, 2002; Birk et al., 2004; Einsiedl, 2005). Potvrdu malog volumena matriksa možemo naći i u koeficijentu recesije koji za oba izvora ukazuje na brzo dreniranje kroz dobro razvijenu mrežu pukotina i kanala.

Volumen freatskih kanala pruža korisne informacije o građi i kapacitetu kanala (Tablica 5.2, str. 49). Prema toj analizi, može se zaključiti da je volumen potopljenih kanala u zaleđu Jaže u prosjeku dvostruko veći naspram Obrva. Još je veća razlika u maksimalnom volumenu potopljenih kanala koji je u slučaju Jaže i više nego dvostruko veći. S druge strane, kod Obrva volumen potopljenih kanala nikad nije pao tako nisko kao u slučaju Jaže. Kod oba izvora ta vrijednost pada prilično nisko, na svega nekoliko stotina kubičnih metara, a kod Jaže čak na manje od stotinu. Sudeći prema tome, može se pretpostaviti da u zaleđima tih izvora nema dubljih okršanih prostora s većim zalihama podzemne vode.

Ako usporedimo volumene freatskih kanala i volumene koji su bili aktivni tijekom trasiranja, opet možemo primijetiti njihovu relativnu bliskost. Njihove vrijednosti su uglavnom u istom redu veličine što objašnjava brzu reakciju izvora na oborine. Tijekom posljednjeg trasiranja ponora P-1 i P-2, u uvjetima velikih voda, volumen kanala dobiven trasiranjem je bio otprilike $40\,000\text{ m}^3$, dok je neposredno prije volumen potopljenih kanala iznosio otprilike $18\,600\text{ m}^3$. Iz tog odnosa se vidi da je

praktički polovica kanala bila potopljena. Tijekom trasiranja u veljači 2012. godine, taj omjer je bio nešto manji. Volumen potopljenih kanala je bio manji od 6 000 m³, dok je ukupni volumen kanala koji su sudjelovali u toku bio veći od 24 000 m³.

8.1.6 Hidrogeološka klasifikacija naslaga na terenu

Vujnović (2010) je naslage gornjotrijaskih glavnih dolomita svrstala u karbonatne naslage dobre propusnosti, a naslage gornjokrednih vapnenačkih breča u karbonatne naslage osrednje propusnosti. Treba naglasiti da je područje njenog istraživanja pokrivalo veću površinu te nije razmatralo lokalne uvjete na području istraživanom u ovom radu. Iz toga i slijedi da je zapravo izvor Obrv smatran glavnim izvorom potoka Jaševnica tj. izvor Jaža se do sada uglavnom zanemarivao jer se smatralo da ima podređenu ulogu.

Tek je ovim istraživanjem utvrđeno da ukupno gledajući, izvor Jaža ima veći kapacitet koji se posebno očituje u uvjetima visokih voda kada njegov kapacitet višestruko premašuje Obrv. Obzirom na rezultate analiza vodnih valova i trasiranja, uočeno je da su volumeni kanala u vodonosniku Jaže pretežno veći od volumena u vodonosniku Obrva. Iznimka je volumen kanala izračunat trasiranjem Jamine pod Piskom, ali taj iznos se treba tretirati s rezervom zbog ne riješenog mehanizma nastanka krivulje koncentracije trasera s dva pika. No, uzimajući u obzir i brzine dobivene tim trasiranjem, možemo pretpostaviti da se radi o nešto manje propusnoj sredini naspram sustava Jaže.

Sve navedeno upućuje na ipak nešto veću propusnost gornjokrednih vapnenačkih breča naspram gornjokrednih glavnih dolomita. Treba naglasiti da su gornjotrijaski glavni dolomiti ispravno deklarirani kao dobro propusni. To pokazuje i koeficijent recesije te brzina odaziva na oborine.

Rezultati ovog istraživanja su pokazali da bi gornjokredne vapnenačke breče bilo ispravno tretirati kao dobro propusne naslage, a ne kao osrednje propusne. Svi podaci ukazuju da je njihova propusnost čak i veća od dobro propusnih gornjotrijaskih dolomita. Prilikom klasifikacije naslaga po propusnosti, primijenjena je

klasifikacija po Šarinu (1988) u kojoj je najpropusnija klasa za karbonatne stijene s pukotinskom propusnosti „dobro propusna“. U skladu s time, gornjotrijaski dolomiti i gornjokredne vapnenačke breče su opisane istom kategorijom propusnosti. Važna napomena je da takav odnos vrijedi na području istraživanja (Slika 4.1, str. 25). Takva propusnost može biti uvjetovana lokalnom tektonikom ili hidrogeološkim sklopom. Pridavanje takve hidrogeološke funkcije istim naslagama u drugim područjima mora biti potkrijepljeno dodatnim lokalnim istraživanjima.

9 ZAKLJUČAK

Na temelju uspostavljenog motrenja dinamike, fizikalno – kemijskih parametara i kemijskog sastava vode, te izvršenih trasiranja i provedenih analiza, proizlaze sljedeći glavni zaključci o vodonosnicima krških izvora Jaže i Obrva:

- Područja napajanja izvora Jaža i Obrv su različita tj. radi se o dva odvojena vodonosnika.
- Područje napajanja izvora Jaža je alogeno s područja „Vivodinskog fliša“ i autogeno kroz vapnenačke breče u zaleđu samog izvora.
- U vodama Jaže pojava magnezija je vezana isključivo za otapanje alumosilikatnih minerala. Modelima miješanja se nije mogao dobiti realni model koji bi uključivao dolomitne vode u slijevu Jaže.
- Područje napajanja izvora Obrv je autogeno s područja gornjotrijaskih glavnih dolomita sjeverno od izvora, te od gornjokrednih vapnenačkih breča sjeverozapadno od izvora.
- Koeficijenti recesije oba izvora ukazuju na brzo dreniranje vodonosnika uslijed velike okršenosti. Tečenje se primarno odvija kroz dobro provodne pukotine i krške kanale.
- Volumen freatskih (potopljenih) kanala je kod Jaže u prosjeku dvostruko veći nego kod Obrva.
- Minimalni zabilježeni volumen freatskih kanala je veći kod Obrva. U slučaju Jaže, minimalni zabilježeni volumen freatskih kanala je manji od 100 m^3 .
- Volumen freatskih kanala je istog ili jedan red veličine manji od volumena kanala utvrđen trasiranjem.
- Veličina kanala dobivena analizom trasiranja jasno korelira s hidrološkim uvjetima. Ovisno o količini vode u sustavu, proporcionalno raste i volumen.
- Analize vremenskih serija pokazuju istovremeno reagiranje Jaže i Obrva, te praktički izostajanje baznog toka. Kašnjenje za oborinama je otprilike 8 do 10 sati.
- U radu je analizirano ukupno devet trasiranja. Pet trasiranja ponora P-1, tri trasiranja ponora P-2 i jedno trasiranje Jamine pod Piskom. Trasiranja su

izvršena u različitim hidrološkim uvjetima. Rezultati tih trasiranja obrađeni su primjenom pet modela (metoda momentata s Chatwinovom metodom, CDE, SFDM, MDM, 2RNE). Pri tome su određeni parametri toka i transporta koji su pokazali veliki raspon vrijednosti ovisno o primijenjenom modelu, a posebno obzirom na hidrološke uvjete koji su bili tijekom pojedinog trasiranja.

- Sva trasiranja ponora P-1 i P-2 su uzrokovala pojavu trasera isključivo na izvoru Jaža
- Visoki pronosi potvrđuju da su ponori P-1 i P-2 podzemno povezani isključivo s izvorom Jaža. Jedina iznimka je u niskim vodama gdje nizak pronos ostavlja mogućnost da dio vode odlazi negdje drugdje ili izbija nizvodnije u koritu potoka Jaševnica te zbog toga nije bio detektiran.
- Trasiranje Jamine pod Piskom je rezultiralo pojavom trasera isključivo na izvoru Obrv.
- Trajanje trasiranja Jamine pod Piskom je bilo daleko najdugotrajnije od svih izvršenih trasiranja. Rezultirajuća krivulja koncentracije trasera se sastoji od dva pika od kojih je drugi veće koncentracije.
- Prividne brzine prvog nailaska su ovisno o hidrološkim uvjetima varirale do dva reda veličine. Minimalne brzine su bile u uvjetima niskih voda, dok je maksimalna brzina bila u uvjetima visokih voda.
- Razlike u srednjoj efektivnoj brzini pokazuju istu tendenciju promjene ovisno o hidrološkim uvjetima kao i prividna brzina, ali je amplituda promjene manja. Razlike su bile maksimalno u jednom redu veličine.
- Dolazak vodnog vala tijekom trasiranja ima mali utjecaj na srednju efektivnu brzinu (malo raste), ali ima veliki utjecaj na disperziju. Ovisno o vremenu preklapanja vodnog vala s traserom, disperzija može biti drastično povećana, ali i drastično smanjena. Preklapanje vodnih valova s nailaskom trasera smanjuje disperziju i povećava utjecaj advekcije, dok nakon prolaska vodnog vala disperzija raste (kao i ukupno trajanje istjecanja trasera).
- Sudeći prema rezultatima izvršenih trasiranja, disperzivnost je prilikom jednolikog protoka najmanja kod srednjih voda, kod niskih voda raste, dok kod visokih voda ima najveće vrijednosti.

- Naslage gornjokrednih vapnenačkih breča na ovoj lokaciji se smatraju dobro propusnim naslagama (do sada su smatrane osrednje propusnim), dok gornjotrijaski glavni dolomiti ostaju klasificirani kao dobro propusni.

Korištenjem i uspoređivanjem rezultata analitičkih modela za analizu izvršenih trasiranja došlo se od sljedećih zaključaka i preporuka:

- Ukoliko želimo u potpunosti interpretirati rezultate trasiranja neophodno je uspostaviti opažanje dinamike vode na mjestima opažanja trasera
- MDM i 2RNE modeli su u najvećem broju slučajeva imali najbolje preklapanje opažane i modelirane krivulje koncentracije. Jedino s tim modelima je moguće simulirati rep krivulje.
- SFDM model u dobro razvijenom krškom vodonosniku poput vodonosnika izvora Jaža nije mogao samostalno simulirati cjelovite opažane krivulje koncentracije.
- Simuliranje krivulja s više pikova je jedino moguće MDM modelom. Krivulje s jednim pikom se isto tako mogu uspješno simulirati, ali se takvi rezultati teško mogu uspoređivati s ostalim modelima.
- Metoda momenata je relativno jednostavna i preporučljiva je metoda za dobivanje polaznih vrijednosti za druge modele.
- CDE model nije u mogućnosti simulirati repove krivulja, ali zahvaljujući jednostavnosti daje jednoznačno rješenje.
- 2RNE model je najsloženiji primijenjeni model obzirom na broj modeliranih parametara. Takva kompleksnost uzrokuje višeznačnost rješenja te je prilikom njegove primjene potreban oprez. Preporuča se usporedba dobivenih parametara s barem još jednim modelom.
- Dobivene vrijednosti srednjeg vremena prolaska trasera su slične među modelima, generalno su nešto veće vrijednosti kod metode momenata i 2RNE modela.
- Promjena dinamike tečenja tijekom trasiranja uzrokuje nesigurnost prilikom rješavanja modela. Dobivene rezultate je potrebno uzeti s oprezom i po potrebi ih korigirati ovisno o dinamičkim uvjetima istjecanja tijekom trasiranja.
- Brzinu tečenja dobivenu trasiranjem pravilnije je izraziti kroz srednju efektivnu brzinu trasera nego prividnom brzinom prvog nailaska. Prividna brzina prvog

nailaska je korisna prvenstveno za studije o zagađivanju, dok srednja efektivna brzina ima fizikalno značenje.

Iz svih navedenih zaključaka proizlazi da je kvantitativno trasiranje puno korisnije za otkrivanje značajki vodonosnika od kvalitativnog trasiranja koje je još uvijek prevladavajući oblik u našim krajevima. Značajke tečenja vode i potencijalnog zagađivača se mogu drastično mijenjati uslijed različitih hidroloških uvjeta. Iz toga slijedi da bi za adekvatno korištenje i zaštitu podzemne vode iz krških vodonosnika, kvantitativna trasiranja trebalo ponavljati u različitim hidrološkim uvjetima, na istim lokacijama.

10 LITERATURA

ASHTON, K. (1966): The analysis of flow in karst drainage systems. Transactions of the Cave Research Group of Great Britain 7, 161-203.

ATKINSON, T.C. (1977): Diffuse and conduit flow in limestone terrain in the Mendip Hills, Somerset (Great Britain). J. Hydrol. 35, 93-103.

ATKINSON, T.C., SMITH, D.I., LAVIS, J.J., WHITAKER R.J. (1973): Experiments in tracing underground waters in limestones. Journal of Hydrology 19; 323-349.

AVANIĆ, R., GRGASOVIĆ, T., PAVELIĆ, D., ŠIMUNIĆ, A., KOVAČIĆ, M. (2000): Litostratigrafske jedinice donjeg trijasa na području Žumberka i Samoborske gore. Zbornik radova 2. Hrvatski geološki kongres Cavtat-Dubrovnik 2000, Zagreb, pp. 71-77.

BEAR, J. (1979): Hydraulics of Groundwater. New York: McGraw-Hill, 567 p.

BECKER, M.W., SHAPIRO, A.M. (2003): Interpreting tracer breakthrough tailing from different forced-gradient tracer experiment configurations in fractured bedrock. Water Resources Research 39 (1), 1024, doi: 10.1029/2001WR001190.

BEHRENS, H., OERTER, H., REINWARTH, O. (1982): Results of tracer experiments with fluorescent dyes on Vernagtferner (Oetzal Alps, Austria) from 1974 to 1982. Zeitschrift für Gletscherkunde und Glazialgeologie, 18 (1), 65-83.

BEZES, C. (1976): Contribution à la modélisation des systèmes aquifères karstiques. Etablissement du modèle BEMER. Ph.D. thesis, University of Montpellier, C.E.R.G.A. publication, volume X (I-II).

BIRK, S., GEYER, T., LIEDL, R., SAUTER, M. (2005): Process-based interpretation of tracer test in carbonate aquifers. Ground Water 43 (3), 381-388.

BIRK, S., LIEDL, R., SAUTER, M. (2004): Identification of localised recharge and conduit flow by combined analysis of hydraulic and physico-chemical spring responses. Urenbrunnen, SW-Germany, Journal of Hydrology, Volume 286, Issues 1–4, pp 179-193.

BOGNAR, A. (1980): Tipovi reljefa kontinentalnog dijela Hrvatske. Spomen-Zbornik o 30. obljetnici Geografskog društva Hrvatske, Zagreb, pp. 39-60.

BOGNAR, A. (2001): Geomorfološka regionalizacija Hrvatske. Acta Geographica Croatica, Vol. 34 (1999), Zagreb, pp. 7-29.

BONACCI, O. (1987): Karst Hydrology. Springer-Verlag, Berlin, 173.

BONACCI, O. (1993): Karst spring hydrographs as indicators of karst aquifers. J. Hydrol: Scinences 38, vol. 1-2, 51-62.

BOUSSINESQ, J. (1877): Essai sur la théorie des eaux courantes do mouvement nonpermanent des eaux souterraines. Acad. Sci. Inst. Fr. 23, 252-260.

BOUSSINESQ, J. (1904): Recherches théoriques sur l'écoulement des nappes d'eau infiltrées dans le sol et sur le débit des sources. J. Math. Pure Appl10, 5-78.

BOX, G.E.P., JENKINS, G.M. (1974): Time Series Analysis: Forecasting and Control. Holden Day, San Francisco, 575.

BRKIĆ, Ž., KUHTA, M., SINGER, D. (2002): Geološka i hidrogeološka osnova Parka prirode „Žumberak-Samoborsko gorje“. Fond stručne dokumentacije Parka prirode „Žumberak-Samoborsko gorje“, Slani Dol.

BUKOVAC, J., POLJAK, M., ŠUŠNJAR, M., ČAKALO, M. (1983): Osnovna geološka karta SFRJ, 1:100.000, list Črnomelj L 33-91, Beograd

BUKOVAC, J., POLJAK, M., ŠUŠNJAR, M., ČAKALO, M. (1984): Osnovna geološka karta SFRJ, 1:100.000, Tumač za list Črnomelj L 33-91, Beograd

BUKOVAC, J., GRGASOVIĆ, T., GLOVACKI JERNEJ, Ž., JERINIĆ, G., GALOVIĆ, I., PRTOLJAN, B. (1995): Litostratigrafska raščlamba dolomitnih naslaga trijasa jugozapadnog Žumberka u okviru radova na geološkoj karti Republike Hrvatske 1:50.000. Zbornik radova 1. Hrvatskog geološkog kongresa Opatija, Zagreb, pp. 137-143.

BUZJAK, N. (2006): Geomorfološke i speleomorfološke značajke Žumberačke gore i geoekološko vrednovanje endokrškog reljefa. Disertacija, PMF, Sveučilište u Zagrebu.

CHATWIN, P.C. (1971): On the interpretation of some longitudinal dispersion experiments. *Journal of fluid mechanics* 48 (4); 689-702.

CSONTOS, L., NAGYMAROSY, A. (1998): The Mid-Hungarian line: a zone of repeated tectonic inversions. Eötvösh University Budapest, Department of Geology, Múzeum krt 4/a, H-1088 Budapest, Hungary.

CVETKOVIĆ, A. (2007): Geološko kartiranje (1:10 000) i strukturna analiza u zoni kontakta trijaskih i gornjokrednih naslaga područja Visoče u JZ Žumberku. Diplomski rad, Sveučilište u Zagrebu, Prirodoslovno-matematički fakultet, Zagreb.

DAVIS, P.M., ATKINSON, T.C., WIGLEY, T.M.L. (2000): Longitudinal dispersion in natural channels: 2. The roles of shear flow dispersion and dead zones in the River Severn, U.K. *Hydrology and Earth Science* 4 (3); 355-371.

DAY, T.J. (1975): Longitudinal dispersion in natural channels. *Water Resources Research* 11 (6); 909-918.

DELIĆ, Z. (1980): Analize okomite razdiobe denudacijskih površina Žumberačke gore sjeverno od Dragonoša i Kalinovice, *Priroda*, 7/8, 224-226.

DESMARAIS, K., ROJSTACZER, S. (2002): Inferring source waters from measurements of carbonate spring response to storms. *Journal of Hydrology* 260, 118-134.

DEWANDEL, B., LACHASSAGNE, P., BAKALOWICZ, M., WENG, PH., AL-MALKI, A. (2003): Evaluation of aquifer thickness by analyzing recession hydrographs, application to the Oman ophiolite hard-rock aquifer, J. Hydrol. 274, 248-269.

DRAGIČEVIĆ, I., BLAŠKOVIĆ, I., MAYER, D., ŽUGAJ, R., TOMLJENović, B. (1997a): Gorski i prigorski vodonosnici sjeverne Hrvatske (Izviješće o radovima u 1996. godini). Fond stručne dokumentacije RGNF, Zagreb.

DRAGIČEVIĆ, I., BLAŠKOVIĆ, I., MAYER, D., ŽUGAJ, R., TOMLJENović, B. (1997b): Gorski i prigorski vodonosnici sjeverne Hrvatske (Izviješće o radovima u 1997. godini). Fond stručne dokumentacije RGNF, Zagreb.

DREISS, S.J. (1989): Regional scale transport in a karst aquifer: 1. Component separation of spring flow hydrographs. Water Resources Research 25, 117-125.

DROGUE, C. (1967): Essai de détermination des composantes de l'écoulement des sources karsiques. Chronique d'Hydrogéologie. Orleans, France: BRGM.

DROGUE, C. (1972): Analyse statistique des hydrogrammes de décrues des sources karstiques, J. Hydrol., 15, 49-68.

DROGUE, C. (1980): Essai d'identification d'un type de structure de magasins carbonates, fissures. Mem H Ser Soc Geol, France, 11, 101-108.

DUJMOVIĆ, I. (1994): Geomorfološke osobine sjeveroistočnog dijela Žumberačke gore. Magistarski rad, PMF, Sveučilište u Zagrebu.

EINSIEDL, F. (2005): Flow system dynamics and water storage of a fissured – porous karst aquifer characterized by artificial and environmental tracers. J. Hydrol. 312, 312-321.

EISENLOHR, L., KIRALY, L., BOUZELBOUDJEN, M., ROSSIER, Y. (1997a): Numerical simulation as a tool for checking the interpretation of karst spring hydrographs. J. Hydrol. 193, 306-315.

EISENLOHR, L., BOUZELBOUDJEN, M., KIRALY, L., ROSSIER, Y. (1997b): Numerical versus statistical modeling of natural response of a karst hydrogeological system. *J. Hydrol.* 202, 244-262.

FIELD, M.S., AND NASH, S.G. (1997): Risk assessment methodology for karst aquifers: (1) Estimating karst conduit-flow parameters. *Environmental Monitoring Assessment* 47;1–21.

FIELD, M.S., AND PINSKY, P.F. (2000): A two-region nonequilibrium model for solute transport in solution conduits in karstic aquifers. *Journal of Contaminant Hydrology* 44; 329–351.

FIELD, M. S. (2002): The QTRACER2 program for tracer-breakthrough curve analysis for tracer test sin karstic aquifers and other hydrologic systems. U.S. Enviromental Protection Agency, 600/R-02/001, 179 p.

FORD, D., WILLIAMS, P. (1989): *Karst Geomorphology and Hydrology*. London: Unwin Hyman.

FORKASIEWICZ, J., PALOC, H. (1967): Le régime de tarissement de la Foux de la Vis. *Chronique d`hydrogéologie* 10, 59-73.

GAJIĆ-ČAPKA, M., PERČEC-TADIĆ, M., PATARČIĆ, M. (2003): Digitalna godišnja oborinska karta Hrvatske. *Hrvatski meteorološki časopis*, 38, 21-33.

GEYER, T., BIRK, S., LICHA, T., LIEDL, R., SAUTER, M. (2007): Multitracer test aproach to charecterize reactive transport in karst aquifers. *Ground Water* 45, 36-45.

GOLDSCHIEDER, N., DREW, D.P. (2007): *Methods in karst hydrogeology*, Taylor & Francis Group, 264 pp, London, UK

GOLDSCHIEDER, N., MEIMAN, J., PRONK, M., SMART, C. (2008): Tracer test in karst hydrogeology and speleology, *International Journal of Speleology*, 37 (1), 27-40. Bologna (Italy). ISSN 0392-6672

GORJANOVIĆ - KRAMBERGER, D. (1894): Geologija gore Samoborske i Žumberačke. Rad JAZU, knjiga CXX, Zagreb, pp. 1-82.

GORJANOVIĆ - KRAMBERGER, D. (1894a): Geološka priegledna karta gore Samoborske i Žumberka, M 1:75.000. JAZU, Zagreb.

GÖPPERT, N., GOLDSCHIEDER, N. (2008): Solute and Colloid Transport in Karst Conduits under Low- and High-Flow Conditions, *Ground Water* 46, 61-68.

GRASSO, D.A. & JEANNIN, P-Y. (1994): Etude critique des méthodes d'analyse de la réponse globale des systèmes karstiques. Application au site de Bure (JU, Suisse). *Bulletin d'Hydrogéologie de l'Université de Neuchâtel*, 13, 87-113.

GRASSO, D.A. & JEANNIN, P-Y. (2002): A Global Experimental System Approach of Karst Springs Hydrographs and Chemographs. *Ground Water* 40, 608-618.

GRGASOVIĆ, T. (1995): Stratigraphy of Middle and Upper Triassic deposits from Zumberak Mt. (W Croatia). 6. International Symposium of Fossil Algae and Carbonate Platforms, Abstracts, 34, Ankara.

GRGASOVIĆ, T. (1997): Upper Triassic Biostratigraphy and Algae from Žumberak (Croatia). *Geologia Croatica*, 50/2, 201-214, Zagreb.

HAUNS, M., JEANNIN, P.-Y., ATTEIA, O. (2001): Dispersion, retardation and scale effect in tracer breakthrough curves in karst conduits. *Journal of Hydrology* 241 (3-4), 177-193.

HERAK, M. (1947): Prilog stratigrafskom raščlanjivanju mezozojskih naslaga jugozapadnog dijela Žumberačke gore. *Geol. Vjesnik I.*, Zagreb, pp. 3-5.

HERAK, M. (1986): A new concept of geotectonics of the Dinarides. *Acta Geologica*, 16/1, (Priř.str. JAZU 53), Zagreb, pp. 1-42.

HERAK, M. & BUKOVAC, J. (1988): Tektonsko okno Duralije u Žumberku. *Geol. Vjesnik*, 41, Zagreb, pp. 231-236.

HERAK, M., JAMIČIĆ, D., ŠIMUNIĆ, A., BUKOVAC, J. (1990): The northern boundary of the Dinarides (Sjeverna granica Dinarida). *Acta Geologica*, 20/1, (Prirodoslovna istraživanja, 60), Zagreb, pp. 5-27.

HERAK, M. (1991): Dinaridi-mobilistički osvrt na genezu i strukturu. *Acta Geologica*, 21/2, (Prirodoslovna istraživanja, 63), Zagreb, pp.1-83 (35-117).

HERAK, M. (1999): Tectonic Interrelation of the Dinarides and the Southern Alps. *Geologia Croatica*, Vol. 52/1, Zagreb, pp. 83-98.

HIRC, D. (1905): Prirodni zemljopis Hrvatske. Knjiga I, 1-721, Zagreb.

HRELIĆ, Đ., ČAKARUN, I., ŠARIN, A. (1994): Hidrogeološka karta Republike Hrvatske, M 1:200.000, list Celje-karta i tumač. *Inst. Geol. Istr.*, Zagreb.

HUBBARD, E.F., KILPATRICK, F.A., MARTENS, L.A., WILSON, J.F. (1982): Measurement of time of travel and dispersion in streams by dye tracing. *U.S. Geological Survey Techniques of Water-Resources Investigations*, Book 3, Chapter A9, 44 p.

JENKINS, G.M., WATTS, D.G. (1968): *Spectral analysis and its applications*. Holden Day, San Francisco, CA, 525.

KÄSS, W. (1998): *Tracing technique in geohydrology*. Balkema, Rotterdam, 581 p.

KEIL, K. (1959): *Ingenieurgeologie und Geotechnik*, 3. Ed., XL + 1456 p. Halle/Saale.

KILPATRICK, F.A., WILSON, Jr. J.F.(1989): Measurement of time and travel in streams by dye tracing. *Techniques of Water-Resources Investigations of the United States Geological Survey*, Book 3. Chapter A9. 27 p.

KOVÁCS, A. (2003): Geometry and hydraulic parameters of karst aquifers: A hydrodynamic modeling approach. PhD thesis, University of Neuchâtel, Switzerland. 131 p.

KUHTA, M., FRANGEN, T., STROJ, A. (2009): Trasiranje tokova podzemne vode s Grobničkog polja, Tehničko izvješće, Fond HGI.

KÖPPEN, W. (1918): Klassifikation der Klimate nach Temperatur, Niederschlag und Jahreslauf, Petermanns Geographische Mitteilungen, 64, 193-203.

KREFT, A., ZUBER, A. (1978): On the physical meaning of the dispersion equation and its solutions for different initial and boundary conditions. Chemical Engineering Science 33; 1471-1480.

KREŠIĆ, N. (1997): Quantitative solutions in hydrogeology and groundwater modeling. Lewis Publishers, 461 str., New York.

LANGBEIN, W.B. (1938): Some channel storage studies and their application to the determination of infiltration. Eos, Transactions, American Geophysical Union 19, 435-447.

LAROCQUE, M., MANGIN, A., RAZACK, M., BANTON, O. (1998): Contribution of correlation and spectral analysis to the regional study of a large karst aquifer (Charente, France). J. Hydrol. 205, 217-231.

LEIBUNDGUT, C. (1974): Fluorezierende Markierfarbstoffe in der Hydrologie. Mitteilungen der Naturforschenden Gesellschaft Bern, 31, 63-84. Berne.

LEIBUNDGUT, C., MALOSZEWSKI, P. AND KÜLLS, C. (2009). Tracers in Hydrology. Wiley-Blackwell, Sussex, 415 pp.

MAILLET, E. (1905): Essais d'hydraulique souterraine et fluvial. Libraire Sci., A. Herman, Paris, 218.

MALOSZEWSKI, P., ZUBER, A. (1985): On the theory of tracer experiments in fissured rocks with porous matrix. Journal of Hydrology 79 (3-4), 333-358.

MALOSZEWSKI, P., HARUM, T., BENISCHKE, R. (1992): Mathematical modelling of tracer experiments in the karst of Lurbach system. Steirische Beiträge zur Hydrogeologie 43, 116-136.

MALOSZEWSKI, P., BENISCHKE, R., HARUM, T., ZOJER, H. (1998): Estimation of solute transport parameters in a karstic aquifer using artificial tracer experiments. In: Shallow Groundwater Systems 18, Dillon, P., Simmers, I. (Ed.), 177-190.

MANGIN, A. (1975): Contribution à l'étude hydrodynamique des aquifères karstiques. These, Université de Dijon, 124.

MANGIN, A. (1981): Utilisation des analyses corrélatrice et spectral dans l'approche des systèmes hydrologiques. Computers Rendues Acad. Sci. Paris, 293, 401-404.

MANGIN, A. (1984): Pour une meilleure connaissance des systèmes hydrologiques à partir des analyses corrélatrice et spectral. J. Hydrol. 67, 25-43.

MILANOVIĆ, P. (1981): Karst Hydrogeology. Water resources publication, Colorado, 434.

MIOČ, P. & PAMIĆ, J. (2002): The continuation of the Internal Dinaridic units in the transitional area between the easternmost periadriatic line and the northernmost southern Alps in Slovenia. Geol. Carpathica, 53. Proceedings of the XVII Congress of Carpathian-Balkan Geological Association, Bratislava, Slovakia.

MOLVAREC, L. (2007): Geološki odnosi i strukturna analiza u zoni kontakta trijaskih i gornjokrednih naslaga područja Bučari u JZ Žumberku. Diplomski rad, Sveučilište u Zagrebu, Prirodoslovno-matematički fakultet, Zagreb.

MULL, D.S., LIEBERMANN, T.D., SMOOT, J.L., AND WOOSLEY Jr., L.H. (1988): Application of dye-tracing techniques for determining solute-transport characteristics of ground water in karst terranes, Rep. EPA 904/6-88-001, U.S. Environmental Protection Agency, Atlanta, Georgia., 103 p.

NÜTZMANN, G., HOLZBECHER, E., STRAHL, G., WIESE, B., LICHT, E., KNAPPE, A. (2005): Visual CXTFIT – a user-friendly simulation tool for modelling one-dimensional transport, sorption and degradation processes during bank filtration. 5th International Symposium on Management of Aquifer Recharge (ISMAR 5), Berlin, Germany.

PADILLA, A., PULIDO-BOSCH, A., MANGIN, A. (1994): Relative importance of baseflow and quickflow from hydrographs of karst spring. *Ground Water*, 32/2, 267-277.

PADILLA, A., PULIDO-BOSCH, A., (1995): Study of hydrographs of karstic aquifers by means of correlation and cross-spectral analysis. *J. Hydrol.* 168, 73-89.

PALMER, A.N. (2007): *Cave geology*. Cave Books, 454 pp, Dayton

PAMIĆ, J. & TOMLJENović, B. (1998): Basic geologic data from the Croatian part of the Zagorje-Mid-Transdanubian Zone. -*Acta Geologica Hungarica*, 41/4, Budapest, pp. 389-400.

PARLOV, J. (2010): Identifikacija parametara za modeliranje toka podzemne vode glavnih izvora Mirne. Doktorska disertacija, Rudarsko-geološko-naftni fakultet, Sveučilište u Zagrebu, 116 str.

PLENIČAR, M., PREMUR, U., HERAK, M. (1975): Osnovna geološka karta SFRJ, 1:100.000, list Novo Mesto, L33-79, Geološki zavod Ljubljana, Savezni geološki zavod Beograd.

PLENIČAR, M., PREMUR, U. (1977): Osnovna geološka karta SFRJ ,1:100.000, Tolmač za list Novo Mesto L 33-79, Geološki zavod Ljubljana, Savezni geološki zavod Beograd.

PLUMMER, L.N., PRESTON, E.C. & PARHURST, D.L.(1994): An interactive code (NETPATH) for modelling net geochemical reactions along flow path, Version 2.0 USGS Water-Resources Investigation Report, 94-4169, Reston, Virginia.

POSAVEC, K., BAČANI, A., NAKIĆ, Z. (2006): A Visual Basic Macrko for Recession Curve Analysis. *Ground Water*, 44/5, 764-767.

POSAVEC, K., PARLOV, J., NAKIĆ, Z. (2010): Fully Automated Objective-Based Method for Master Curve Separation, *Ground Water*, 48/4, 598-603.

PRINZ, E. (1923): *Handbuch der Hydrologie*, 2.Ed., 422 p. Berlin: Springer

PRTOLJAN, B. (2001): Relations of thrust-fold and horizontal mechanism of the Mt.Žumberak part of the Savva nappe in northwestern Dinarides, West Croatia. *Acta Geologica Hungarica*, Vol. 44/1, Budapest, pp. 67-80.

RIGGS, H.C. (1968): Techniques of Water-Resources Investigations of the United States Geological Survey, chapter A1, Some statistical tool sin hydrology. Book 4, 39 str.

RYAN, M., MEIMAN, J. (1996): An exemination of short-term variations in water quality at a spring in Kentucky. *Ground Water* 34 (1), 23-30.

SALOPEK, M., (1912): O srednjem trijasu Gregurić brijega u Samoborskoj gori i o njegovoj fauni. *Djela JAZU*, 20, Zagreb, pp. 1-34.

SAUTER, M. (1992): Quantification and forecasting of regional groundwater flow and transport in a karst aquifer (Gallusquelle, Malm, SW-Germany). *Tübinger Geowissenschaftliche Arbaiten* C13, pp. 150.

SCHNEGG, P.-A., DOERFLIGER, N. (1997): An inexpensive flow-through field fluorometer. *Proc. of the 6e Colloque d'hydrologie en pays calcaire et milieu fissuré*, la Chaux-de-Fonds, August 1997.

SCHNEGG, P.-A. (2002): An inexpensive field fluorometer for hydrogeological tracer tests with three tracers and turbidity measurement. *XXXII IAH & ALHSUD Congress Groundwater and Human Development*. Balkema, Mar del Plata, Argentina, pp. 1484-1488.

SCHNEGG, P.-A. (2003): A new field fluorometer for multi-tracer tests and turbidity measurement applied to hydrogeological problems. *Proc. of the 8th International Congress of the Brazilian Geophysical Society*, Rio de Janeiro, Brazil.

SEMERL, R. (1979): Geomorfološki razvoj Žumberačke gore sjeverno od potoka Bregane do rijeke Save, *Priroda*, 10, 300-302.

SMART, C.C. (1988a): Artificial tracer techniques for determination of the structure of conduit aquifers. *Ground Water* 26, 445-453.

SMART, C.C. (1988b): Quantitative tracing of the Maligne karst system, Alberta, Canada, *Journal of Hydrology*, Volume 98, Issues 3–4, 15 April 1988, p. 185-204.

SNYDER, F.F. (1939): A concept of runoff-phenomena. *Eos, Transactions, American Geophysical Union* 20, 725-738.

SOKAČ, B. & GRGASOVIĆ, T. (1998): *Asterocalculus heraki* n.gen., n.sp., a new calcareous alga (Gymnocodiaceae) from the Upper Triassic Haupt-dolomite of Žumberak, north Croatia. *Facies*, 38.

STROJ, A. (2007): Metode analize i interpretacije krških izvora. Seminarski rad, Rudarsko-geološko-naftni fakultet, 39 str., Zagreb.

STROJ, A. (2010): Podzemni tokovi u zaleđu krških priobalnih izvora na području Velebitskog kanala. Disertacija, Rudarsko-geološko-naftni fakultet, Sveučilište u Zagrebu, 259 str.

SUDICKY, E.A., FRIND, E.O. (1982): Contaminant transport in fractured porous media: analytical solutions for a system of parallel fractures. *Water Resources Research* 18 (6), 1634-1642.

SWEETING, M.M. (1973): *Karst Landforms*. Columbia Univ. Press, New York, NY, 362 p.

ŠARIN, A., BAHUN, S., FRITZ, F., KRANJEC, V., URUMOVIĆ, K. (1980): Hidrogeološka karta SR Hrvatske, M 1:500.000. Tumač. Inst. Geol. Istr., Zagreb.

ŠARIN, A. (1988): Upute za izradu Osnovne hidrogeološke karte Jugoslavije, M 1:100.000. Drugo, izmijenjeno i dopunjeno izdanje. Savezni geološki zavod, Beograd.

ŠIKIĆ, K. (1995): Geološki vodič Medvednice, Inst. geol. istraž., Zagreb.

ŠIKIĆ, K., BASCH, O., ŠIMUNIĆ, A. (1977): Osnovna geološka karta SFRJ, 1:100.000, list Zagreb, L38-80. Institut za geološka istraživanja Zagreb, Savezni geološki zavod Beograd.

ŠIKIĆ, K., BASCH, O., ŠIMUNIĆ, A. (1979): Osnovna geološka karta SFRJ, 1:100.000. Tumač za list Zagreb, L38-80. Institut za geološka istraživanja Zagreb, Savezni geološki zavod Beograd.

ŠIKIĆ, D. I PRELOGOVIĆ, E. (1970): O tektonskim pokretima u Žumberačkoj i Samoborskoj gori. 7. Kongres geologa SFRJ, 1, Zagreb.

TOMLJENović, B., CSONTOS, L. (2001): Neogene-Quaternary structures in the border zone between Alps, Dinarides and Pannonian Basin (Hrvatsko zagorje and Karlovac Basins, Croatia). Int J Earth Sciences (Geol Rundsch) 90/560-578.

TOMLJENović, B. (2000): Middle Miocene extension at the south-western corner of the Pannonian Basin: surface data on faults and paleo-stress field. Rom J Tect Res Geol 77 Europrobe Abstr vol, p 28.

TORIDE, N., LEIJ, F.J., & VAN GENUCHTEN, M.T. (1999): The CXTFIT code for estimating transport parameters from laboratory or field tracer experiments. US Salinity Laboratory, USDA, ARS, Riverside, CA

TSANG, C.F., NERETNIEKS, I. (1998): Flow channeling in heterogeneous fractured rocks. Reviews in Geophysics 36 (2), 275-298.

TSANG, Y.W., TSANG, C.F. (1987): Channel model of flow through fractured media. Water Resources Research 23 (3), 476-479.

URUMOVIĆ, K., DUIĆ, Ž., HLEVNJAK, B. (2009): Hidrogeološko značenje koeficijenta recesije na primjeru istarskih izvora. Rudarsko-geološko-naftni zbornik 21, 25-34, Zagreb.

VAN GENUCHTEN, M.T. (1981): Non-equilibrium transport parameters from miscible displacement experiments, 88p., US Salinity Laboratory, USDA, ARS, Riverside, CA

VRSAJKO, A (2008): Geološko kartiranje (1:10 000) i strukturna analiza u zoni kontakta trijaskih i gornjokrednih naslaga područja Duboka Draga u JZ Žumberku. Diplomski rad, Sveučilište u Zagrebu, Prirodoslovno-matematički fakultet, Zagreb.

VUJNOVIĆ, T. (2010): Hidrogeološke značajke Park prirode "Žumberak – Samoborsko gorje", Doktorska disertacija, RGNF, Sveučilište u Zagrebu.

ZANINOVIĆ, K., SRNEC, L., PERČEC-TADIĆ, M. (2004): Digitalna godišnja temperaturna karta Hrvatske. Hrvatski meteorološki časopis, 39, 51-58.

WILLIAM B.W., (2002): Karst hydrology: Recent developments and open questions. Engineering Geology, Volume 65, Issues 2–3, pp 85-105

WILLIAMS, P.W. (1983): The role of the subctaneous zone in the karst hydrology. Journal of Hydrology 61, 45-67.

WITTHÜSER, K., REICHERT, B., HÖTZL, H. (2003): Contaminant transport in fractured chalk: Laboratory and field experiments. Ground Water 41 (6), 806-815.

WERNER, A., HÖTZL, H., MALOSZEWSKI, P. AND KÄSS, W. (1997): Interpretation of tracer tests in karst systems with unsteady flow conditions. Karst Hydrology. IAHS Publ.No. 247, pp. 15-26.

WERNLI, H.R. (1986): Naphtionat – ein neuer fluorezenztracer zur wassermarkierung. Deutsche Gewässerkundl. Mitt. (DGM), 16-19.

WORTHINGTON, S.R.H. (1991): Karst hydrology oft he Canadian Rocky Mountains. Ph.D. Dissertation. McMaster University, Hamilton, Ontario, Canada. 380 p.

www.nn.hr Narodne novine broj 55/02, 66/11, 47/13

<http://www.speleo-klub-samobor.hr>

ŽIVOTOPIS

OSOBNI PODACI:

- Ime i prezime: Tihomir Frangen
- E-mail: tihomir.frangen@hgi-cgs.hr
- Datum i mjesto rođenja: 5.1.1980., Zagreb

OBRAZOVANJE:

- 1998. godine završio Kemijsku i geološku tehničku školu, smjer Geološki tehničar
- 2006. godine diplomirao na Rudarsko-geološko-naftnom fakultetu u Zagrebu, studij geologije, smjer Hidrogeologija i inženjerska geologija
- 2008. godine upisao doktorski studij na Rudarsko-geološko-naftnom fakultetu u Zagrebu na smjeru Geološko inženjerstvo

ZAPOSLENJE I RADNO ISKUSTVO

- Od 2007. do 2013. radi u Hrvatskom geološkom institutu kao asistent na znanstvenom projektu Osnovna hidrogeološka karta Republike Hrvatske.
- Od 2013. radi u Hrvatskom geološkom institutu kao stručni suradnik
- Sudjelovao u izvedbi niza projekata vezanih uz hidrogeološka istraživanja i zaštitu podzemnih voda u krškom području Hrvatske.

ZNANSTVENI INTERESI:

- Hidrogeologija krša
- Zaštita podzemnih voda
- GIS
- Inženjerska geologija

OBJAVLJENI RADOVI:

- Terzić, Josip; Pavičić, Ante; Frangen, Tihomir; Marković, Tamara; Lukač Reberski, Jasmina; Dolić, Mario. Groundwater resources sanitary protection zones: two case studies from the Croatian karst // 6th EUREGEO - European Congress on Regional Geoscientific Cartography and Information Systems - Proceedings / Bayerisches Landesamt für Umwelt (ur.). Augsburg, 2009. 225-228 (poster, međunarodna recenzija, objavljeni rad, znanstveni).

- Stroj, Andrej; Kuhta, Mladen; Frangen, Tihomir. Bathyphreatic characteristics of some large springs in Dinaric karst of Croatia // Dinaric karst. Postojna : Karst Research Institute ZRC SAZU , 2010. (poster,međunarodna recenzija,sažetak,znanstveni).
- Terzić, Josip; Frangen, Tihomir. Hidrogeološka istraživanja vodoopskrbnih zdenaca na krškom izvoru rijeke Čikole // Prvi hrvatski speleološki kongres s međunarodnim sudjelovanjem. Sažeci radova. / Garašić, Mladen ; Kovačević, Meho Saša (ur.). Zagreb : Hrvatski speleološki savez, 2010. 71-72 (predavanje,domaća recenzija,sažetak,znanstveni).
- Kuhta, Mladen; Frangen, Tihomir; Stroj, Andrej. Istovremeno trasiranje ponora Rupa i bušotine DB-1 na Grobničkom polju // 4. Hrvatski geološki kongres. Knjiga sažetaka. / Horvat, Marija (ur.). Zagreb : Hrvatski geološki institut, 2010. 203-204 (predavanje,sažetak,znanstveni).
- Terzić, Josip; Frangen, Tihomir; Brajković, Zdravko; Urumović, Kosta. Pokusno crpljenje i kretanje razina podzemne vode u eksploatacijskim zdencima na krškom izvoru rijeke Čikole // 4. Hrvatski geološki kongres - Knjiga sažetaka / Horvat, Marija (ur.). Zagreb : Hrvatski geološki institut, 2010. 235-236 (poster,domaća recenzija,sažetak,znanstveni).
- Marković, Tamara; Roller-Lutz, Zvezdana; Lukač-Reberski, Jasmina; Pavičić, Ante; Stroj, Andrej; Frangen, Tihomir; Brkić, Željka; Hunjak, Tamara; Mance, Diana; Lutz, Hans. Primjena hidrokemijskih pokazatelja i stabilnih izotopa kisika i vodika u hidrogeološkim istraživanjima krških sustava:pokusno područje - izvori rijeke Gacke // Knjiga sažetaka / Horvat Marija (ur.). Zagreb : Hrvatski geološki institut, 2010. 215-216 (poster,domaća recenzija,sažetak,znanstveni).
- Kuhta, Mladen; Frangen, Tihomir; Stroj, Andrej. Speleološka istraživanja na trasi Jadranske autoceste od Zagvozda do Ravče // 4. Hrvatski geološki kongres. Knjiga sažetaka. / Horvat, Marija (ur.). Zagreb : Hrvatski geološki institut, 2010. 330-331 (predavanje,sažetak,znanstveni).
- Frangen, Tihomir; Tomljenović, Bruno; Perković, Dario. Baza podataka o seizmotektonskoj aktivnosti u Hrvatskoj // Zbornik sažetaka / Filipović, Alojz (ur.). Neum : Udruženje/udruga geologa Bosne i Hercegovine, 2008. 93-94 (predavanje,sažetak,znanstveni).
- Terzić, Josip; Stroj, Andrej; Frangen, Tihomir. Hydrogeologic investigation of karst system properties by common use of diverse methods: a case study of Lička Jesenica springs in Dinaric karst of Croatia // Hydrological processes. 26 (2012), 21; 3302-3311 (članak, znanstveni)